



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY



**FAKULTA PODNIKATELSKÁ
ÚSTAV MANAGEMENTU**

FACULTY OF BUSINESS AND MANAGEMENT
INSTITUT OF MANAGEMENT

VYUŽITÍ PROSTŘEDKŮ UMĚLÉ INTELIGENCE NA KAPITÁLOVÝCH TRZÍCH

THE USE OF MEANS OF ARTIFICIAL INTELLIGENCE FOR THE DECISION MAKING
SUPPORT ON STOCK MARKET

Diplomová práce
MASTER'S THESIS

AUTOR PRÁCE
AUTHOR

Bc. MICHAL HAMERNÍK

VEDOUCÍ PRÁCE
SUPERVISOR

prof. Ing. PETR DOSTÁL, CSc.

BRNO 2011

ZADÁNÍ DIPLOMOVÉ PRÁCE

Hamerník Michal, Bc.

Řízení a ekonomika podniku (6208T097)

Ředitel ústavu Vám v souladu se zákonem č.111/1998 o vysokých školách, Studijním a zkušebním řádem VUT v Brně a Směrnicí děkana pro realizaci bakalářských a magisterských studijních programů zadává diplomovou práci s názvem:

Využití prostředků umělé inteligence na kapitálových trzích

v anglickém jazyce:

The Use of Means of Artificial Intelligence for the Decision Making Support on Stock Market

Pokyny pro vypracování:

Úvod
Vymezení problému a cíle práce
Teoretická východiska práce
Analýza problému a současné situace
Vlastní návrhy řešení, přínos návrhů řešení
Závěr
Seznam použité literatury
Přílohy

Seznam odborné literatury:

- AZOFF, E. M. Neural Network Time Series Forecasting of Financial Markets. John Wiley & Sons Inc., 1994. 196 s. ISBN 0-471-94356-8.
- BOSE, K., LIANG, P. Neural Network, Fundamental with Graphs, Algorithm and Applications. Mc. Graw-Hill, 1996. 478 s. ISBN 0-07-114064-6.
- DOSTÁL, P. Pokročilé metody analýz a modelování v podnikatelství a veřejné správě. 1. vyd. Brno : CERM, 2008. 340 s. ISBN 978-80-7204-605-8.
- DOSTÁL, P., SOJKA, Z. Financial Risk Management. Zlín : UTB, 2008. 80 s. ISBN 978-80-7318-772-9.
- DOSTÁL, P. Advanced Economic Analyses. Brno : CERM, 2008. 80 s. ISBN 978-80-214-3564-3.
- HANSELMAN, D., LITTLEFIELD, B. Mastering MATLAB7. Pearson Education International Ltd., 2005. 852 s. ISBN 0-13-185714-2.
- REJNUŠ, O. Finanční trhy. Ostrava : Key Publishing, 2008. 559 s. ISBN 978-80-87071-87-8.
- THE MATHWORKS. MATLAB – Neural Network Toolbox - User's Guide. The MathWorks Inc., 2010.

Vedoucí diplomové práce: prof. Ing. Petr Dostál, CSc.

Termín odevzdání diplomové práce je stanoven časovým plánem akademického roku 2010/2011.

L.S.

PhDr. Martina Rašticová, Ph.D.
Ředitel ústavu

doc. RNDr. Anna Putnová, Ph.D., MBA
Děkan fakulty

V Brně, dne 20.05.2011

Abstrakt

Diplomová práce se zaměřuje na problematiku a následnou aplikaci vybraných metod umělé inteligence na kapitálových trzích - konkrétně se jedná o využití umělých neuronových sítí za účelem predikce hodnoty a určení trendu vývoje investičního nástroje. Vlastní řešení je vytvořeno za pomoci vývojového prostředí Matlab a následně vyhodnoceno.

Abstract

This diploma thesis focuses on the problem and subsequent application of selected methods of artificial intelligence used on stock markets – especially the use of artificial neural networks to forecast the values and determination of the trend of investment instruments. Solutions are created by using Matlab development environment and subsequently evaluated.

Klíčová slova

Umělé neuronové sítě, technická analýza, predikce, kapitálový trh,

Keywords

Artificial neural networks, technical analysis, forecasting, stock market

Bibliografická citace

HAMERNÍK, M. Využití prostředků umělé inteligence na kapitálových trzích. Brno: Vysoké učení technické v Brně, Fakulta podnikatelská, 2010. 77 s. Vedoucí diplomové práce prof. Ing. Petr Dostál, CSc.

Čestné prohlášení

Prohlašuji, že předložená diplomová práce je původní a zpracoval jsem ji samostatně. Prohlašuji, že citace použitých pramenů je úplná, že jsem v práci neporušil autorská práva (ve smyslu zákona č. 121/200 Sb. O právu autorském a o právech souvisejících s právem autorským).

V Brně dne

.....
podpis

Poděkování

Na tomto místě bych rád poděkoval panu prof. Ing. Petru Dostálovi, CSc. za jeho pomoc, rady a připomínky v průběhu zpracovávání této diplomové práce.

Dále bych rád poděkoval Mgr. Miroslavu Mixovi za poskytnutí informací o společnosti.

Obsah

1. Úvod	10
2. Popis a historie společnosti	11
2.1. SWOT analýza	14
2.1.1. Silné stránky	14
2.1.2. Slabé stránky	15
2.1.3. Příležitosti	16
2.1.4. Hrozby	16
2.2. SLEPT analýza	17
2.2.1. Sociální faktory	17
2.2.2. Legislativní faktory	17
2.2.3. Ekonomické faktory	18
2.2.4. Politické faktory	18
2.2.5. Technologické faktory	18
2.3. Porterův model konkurenčního prostředí	19
2.3.1. Vyjednávací síla odběratelů	19
2.3.2. Vyjednávací síla dodavatelů	19
2.3.3. Hrozba nových konkurentů	20
2.3.4. Hrozba substitutů	20
2.3.5. Rivalita mezi stávajícími konkurenty	21
Teoretická východiska práce	22
3. Neuronové sítě	22
3.1. Biologický neuron	22
3.2. Umělý neuron	24
3.3. Modely neuronových sítí	25
3.3.1. Lineární model	25
3.3.2. Vícevrstvé neuronové sítě	25
3.3.3. Radial Basis Function	26
3.3.4. Generalized Regression Neural Network	27
3.3.5. Probabilistický model neuronové sítě	27
3.3.6. Kohonenova neuronová síť	27
3.4. Přenosové (aktivační) funkce	28

3.5.	Učení neuronových sítí	30
3.6.	Obscné schéma práce neuronové sítě	32
4.	Kapitálový trh.....	34
4.1.	Vznik a vývoj kapitálových trhů	34
4.1.1.	Vznik a vývoj burzovnictví	34
4.2.	Faktory ovlivňující rozhodování investora.....	35
5.	Predikce a technická analýza	36
5.1.	Predikce časových řad	36
5.2.	Technická analýza.....	37
6.	Výpočetní systém Matlab	40
	Vlastní návrhy řešení	41
7.	Nelineární autoregresní model (NAR)	42
7.1.	Vyhodnocení NAR modelu	47
7.2.	Optimalizace NAR modelu	48
8.	Nelineární autoregresní model s exogenními vstupy (NARX)	52
8.1.	Vyhodnocení NARX modelu	56
8.2.	Optimalizace NARX modelu	62
9.	Závěr	66
10.	Seznam použité literatury a zdrojů	67
27.	Seznam obrázků	69
28.	Seznam tabulek	70
29.	Seznam příloh	71

1. Úvod

Jednadvacáté století je možné považovat za století dynamické a plné změn, a ačkoliv se nacházíme stále na začátku tohoto století, tak rozvoj, vývoj a inovativnost můžeme sledovat nejen ve všech vědních oborech, ale také i v oblastech lidských činností.

Veškeré technické vymoženosti nám nejenom usnadňují život a posouvají nás dopředu, ale zároveň nás motivují k tomu, abychom chtěli ještě více. Pokud chceme své potřeby a přání uspokojit musíme mít dostatek finančních prostředků, které můžeme investovat.

Nejinak je tomu i v podnikatelské sféře. Zde jsou investice směřovány zejména do oblastí, které mohou podnikatelským subjektům přinášet zisky. A jako nejjednodušší a snad i nejrychlejší způsob jak zhodnotit kapitál se jeví investice na kapitálových trzích, který však s sebou nese určitá rizika. Tato rizika jsou spojena zejména s určením vhodného okamžiku pro provedení vlastního rozhodnutí.

Obchodování na kapitálových trzích není tak jednoduché jak se na první pohled může zdát. Spíše je tomu naopak. Pokud chceme vstoupit na kapitálový trh, musíme si uvědomit, že vstupujeme do velmi komplexního systému, který se mění každým okamžikem, že musíme vycházet z různých druhů analýz a být připraveni na mnoho různých možností následného rozhodování. Navíc okamžik, ve kterém je rozhodnutí provedeno, ovlivňuje výsledek – tedy zda je případná investice profitabilní nebo ztrátová.

Z těchto důvodů společnosti, které mají dostatek volného kapitálu, naprosto cíleně vyhledávají pro svá rozhodnutí podporu. Tuto podporu jim může nabídnout využití umělé inteligence. A v případě této diplomové práce půjde o využití umělých neuronových sítí.

Cílem diplomové práce na téma: „Využití prostředků umělé inteligence na kapitálových trzích“ je nabídnout společnosti s dostatkem peněžních prostředků k investování na kapitálových trzích, které tato problematika není zcela neznámá, predikční modely, které by její rozhodování při investicích na kapitálových trzích nejen usnadnily, ale zároveň by mohly významným způsobem přispět k zajištění výnosnosti investovaného kapitálu.

2. Popis a historie společnosti¹

Společnost **MIXA Vending s. r. o.** zahájila svou činnost v roce 1993 v oblasti vendingu (provozování prodejních a nápojových automatů) tím, že v regionu severní Moravy začala provozovat síť nápojových automatů. V současné době má firma významné postavení v celé oblasti Moravy a Slezska na trhu v segmentu zabezpečování pitného a stravovacího režimu ve firmách, a to jak pro zaměstnance, tak i pro návštěvníky, na úřadech či na veřejných prostranstvích. Společnost **MIXA Vending, s. r. o.** (dále jen společnost) rovněž dodává produkty provozovněm veřejného stravování.

Společnost je zaměřena na dvě hlavní oblasti podnikání, a to na prodejní aktivity a nabídku služeb.

Mezi hlavní prodejní aktivity společnosti patří:

Prodej automatů

- Automaty na teplé nápoje,
- Automaty na kusové zboží,
- Automaty na cigarety,
- Automaty na mléko,
- Automaty na prodej fresh juice z čerstvě vymačkaných pomerančů.

Prodej přístrojů určených na výdej vody

- Sodobary pro úpravu a výdej vody z vodovodního řádu,
- Aquabary na balenou přírodní vodu.

Prodej kávovarů a mlýnků na kávu

- Kávovary na zrnkovou či instantní kávu, popř. využívající porcované kapsle

Prodej a zajišťování surovin

- Instantní suroviny, káva, čaje, kelímky, voda, atd.

Prodej platebních systémů

- Mincovníky,
- Čtečky bankovek,
- Bezhotovostní platební systémy,
- Telemetrie.

¹ MIXA Vending – Profil společnosti [17]

Služby

Pronájem automatů

Pronájem je možností jak získat prodejní nebo nápojový automat případně kávovar včetně příslušenství. Nájemce neinvestuje do nákupu nového přístroje, nýbrž platí pouze měsíční nájem. Například u nápojového automatu si objednatel - nájemce nakupuje pouze suroviny, sám si také stanovuje prodejní ceny a tržba mu zůstává.

V případě, že se nájemce rozhodne nápojový automat v průběhu nájemního období odkoupit, uhrazená částka za nájem plus běžný úrok se k danému datu odečtou z kupní ceny automatu.

Cafeservis

Společnost MIXA Vending s.r.o. je jediným smluvním partnerem Nestlé Česko s.r.o. pro severní Moravu, která zajišťuje instalaci a servis nápojových automatů. Při využití tohoto programu získá zákazník zdarma automat, neplatí žádný nájem a podmínkou je pouze měsíční odběr kávy. Takové řešení je ideální pro hotely a penziony, restaurace, kavárny, bistra, rychlá občerstvení a sezonní provozovny.

Výhody této služby jsou následující:

- široký sortiment kvalitních surovin a nápojů,
- profesionální podpora a servis s poradenstvím,
- snadná a rychlá obsluha jak pro zákazníka, tak pro obsluhu,
- přesná evidence vydaných nápojů,
- bezodpadová technologie.

Ke každé instalaci je možno pořídit materiály pro podporu prodeje jako jsou originální šálek Nescafé, sklenice Nescafé na horké nápoje, rozetky, plastové podnosy, stojánek „RESERVE“, plastový stojánek a nápojový lístek Nescafé, trička pro obsluhující personál, nabídkové tabule, slunečník aj.

Provozování vlastních automatů

Společnost díky znalosti tržního prostředí působí také na trhu provozování vlastních prodejních automatů na různých místech kraje.

Servis a pozáruční servis

- **Servis**

Společnost zabezpečuje kompletní servis firmám, organizacím i fyzickým osobám v oblasti nejen dodávek, provozování, pronájmu a prodeje všech nápojových technologií, ale i prodejních automatů včetně školení.

- **Pozáruční servis**

Společnost zajišťuje kompletní záruční a pozáruční servis nápojových technologií a automatů. Opravy jsou řešeny maximálně do 48 hodin od nahlášení závady přímo na místě u zákazníka. Servis je zajištěn zkušenými servisními technikami, kteří jsou vyškoleni přímo u výrobce. Existuje také možnost objednání sanitace u nápojových produktů (odstranění vodního kamene a desinfekci).

2.1. SWOT analýza

SWOT analýza je nástroj, sloužící k identifikaci silných a slabých stránek, hrozeb a příležitostí, které jsou svázány se společností. SWOT analýza zhotovená pro společnost MIXA Vending, s.r.o. je graficky znázorněna na Obrázku 1.



Obrázek 1. SWOT analýza společnosti, zdroj: vlastní

(Zdroj: vlastní)

2.1.1. Silné stránky

Důvěryhodnost, zkušenost a zaběhlou značku si společnost buduje již od roku 1993. Tyto faktory podmiňuje **ziskovost** po celou dobu existence společnosti, čímž je dána také ekonomická stabilita společnosti, schopnost dostát svým závazkům včas, což v dlouhodobém časovém horizontu může přinášet benefity od dodavatelů i při menších

odběrech. Společnost je schopna rychle reagovat na problémy zákazníků a díky tomu se projevil jejich nárůst jak do počtu, tak i do spokojenosti.

Operativnost společnosti je dána včasným zajištěním provozování nejenom pitného režimu na mnoha místech regionu.

Výhradní zastoupení společností Azkoyen (automaty), Harting Vending (cigaretové automaty), Coges (platební systémy) pro Českou a Slovenskou republiku přidává společnosti status významného hráče na daných trzích.

Široká nabídka produktů a služeb je dána portfoliem společnosti a zaměřením se na více segmentů trhu – od prodeje a pronájmu až po samostatné provozování automatů.

Díky investicím do rozvoje společnosti se **technické zázemí** a využívané technologie neustále modernizují a v současné době již existují a také se využívají technologie, které například dokážou zákazníkovi z automatu předat skleněné zboží, knihy, chlazené potraviny nebo také jsou schopny v případě nutnosti zkontrolovat věk zákazníka, umožňují bezhotovostní platby anebo díky telemetrii kontrolu stavu zásob v automatech v reálném čase – online.

Technické zázemí a technologická úroveň nabízených produktů je také dána **výhradním zastoupením** významných hráčů na poli vendingu což s sebou přináší přístup k moderním přístrojům jak po konstrukční tak i technologické stránce.

2.1.2. Slabé stránky

Slabé stránky jsou managementu společnosti velmi dobře známy, a proto je jejich převážná část v obdobném znění uvedena v sekci „Příležitosti“, protože existují plány a scénáře na jejich snížení či eliminaci.

Majitel v operativním řízení – zahlcení jedné osoby při řízení má za následek vznikající prodlevy při rozhodování.

Pohledávky po splatnosti u odběratelů eviduje společnost ve výši cca 3 miliónů korun, což je částka, která by se dala vhodně využít například při restrukturalizaci společnosti.

Prezentace společnosti – společnost se v současné době prezentuje na svých webových stránkách, na kterých se však vyskytují chyby, a to zrovna nevytváří dobrý dojem stejně jako některé malé chyby v oblasti kódování.

Pasivní (reaktivní) obchod – pasivní neboli reaktivní obchod označuje takový stav, kdy reakce nastane až poté, co nastane určitý podnět. V praxi to znamená, že zákazníci vyhledávají služby společnosti.

2.1.3. Příležitosti

Nové technologie – díky technologickým inovacím a rostoucí náročnosti zákazníků na produkty a služby se společnost přizpůsobuje trhu, a tak je již možné zákazníkovi díky výtahovým technologiím distribuovat například křehké zboží (Štramberské uši, skleněné láhve), v případě nutnosti ověřit věk před výdejem specifického zboží, využívat bezhotovostních platebních systémů případně akceptovat bankovky nebo využívat kontrolu stavu přístrojů v reálném čase.

Pozitivní **růst ekonomiky** a vývoj ukazatele nezaměstnanosti je pro společnost určitým vodítkem, který se odráží na tržbách společnosti. Aktuální růst HDP je 2,6% a míra nezaměstnanosti 9,6% a trend naznačuje mírný pokles ukazatele [9].

Změna firemní kultury/systému řízení je projekt v časovém horizontu 3- 5 let, jehož výstupem by měla být změna myšlení ve společnosti a s tím spojeno delegování a vymezení pravomocí, oblasti činností a požadavků směrem od majitele mezi více osob.

Tvorba **grafického manuálu** by měla být základním kamenem vizuální identity společnosti. Jedná se o ucelený grafický a typografický návrh loga, barevného schématu, hlavičkového papíru, elektronických dokumentů apod.

Proaktivní obchodní činnost je strategicky promyšlená a záměrně budovaná činnost s primárním zaměřením na zákazníka, která by měla pomoci více oslovit nejenom nové, ale i stávající zákazníky.

2.1.4. Hrozby

Korupce – ačkoliv Ministerstvo vnitra se dle svých vyjádření neustále s korupcí snaží bojovat vydáváním různých manuálů pro občany, tak index vnímání korupce (Corruption Perception Index; CPI) dle Transparency International je stále na velmi vysoké hladině [23].

Na hrozbu **konkurence** můžeme nahlížet ve dvou rovinách. První je, že na trh vstoupí společnost (zahraniční) se silným kapitálem, a druhá, že v oblasti dodávky surovin, kdy se místní podnikavý jedinec může rozhodnout, že v oblasti nízkonákladového zboží bude dodávat společností suroviny výrazně pod cenou a může tak zdegenerovat trh, protože takovýto stav dlouhodobě neudrží.

Změna daňové soustavy, zejména změna nižší sazby DPH, a neschopnost politiků domluvit se na postupu jejího zvyšování, ovlivňuje nejenom zdražení surovin, ale také cenotvorbu v konkurenčním prostředí.

Odchody obchodníků ke konkurenci se získaným know-how, databází zákazníků a chováním společnosti nepříjemně ovlivňuje tržní prostředí společnosti.

2.2. SLEPT analýza

2.2.1. Sociální faktory

Demografické ukazatele naznačují, že průměrný stav obyvatelstva vykazuje v průběhu posledních několika let mírně narůstající trend a společně s nezaměstnaností se udržuje přibližně na stejné hladině. Bohužel v Moravskoslezském kraji je nezaměstnanost jedna z nejvyšších v republice a to ovlivňuje nejen chuť a koupěschopnost obyvatelstva, ale ve výsledku i odbyt společnosti [10].

Jiná statistika uvádí, že v roce 2010 vzniklo 23 634 společností a že v průběhu několika minulých let bylo toto číslo obdobné. Ve více než polovině případů se jedná o nový byznys, kdy kapitál do vznikajících společností vložili noví investoři a pro společnost se tak neustále otevírají možnosti [8].

2.2.2. Legislativní faktory

Snížená sazba DPH výrazně ovlivňuje podnikatelské subjekty v cenotvorbě, protože se její hodnota neustále zvyšuje (5% -> 9% -> 10% -> 14%? -> 17,5%?). Tato postupná zvyšování daní mají vliv na zdražování potravin a nápojů. Takovéto zvyšování má rovněž negativní vliv na sociální faktory.

Od roku 2012 se celková minimální spotřební daň z jedné cigarety podle návrhu má zvýšit o devět haléřů, tedy na 2,10 koruny za kus. Ministerstvo financí navrhuje zvýšit sazby spotřební daně z tabákových výrobků v postupných krocích, po růstu v roce 2012 by další zvýšení daně mělo následovat o dva roky později. Další změna je plánována k 1. lednu 2014, přičemž zvýšení se bude odrážet od aktuálního kurzu eura vůči české koruně s cílem dosáhnout minimálních sazeb spotřební daně stanovených směrnicí [22].

2.2.3. Ekonomické faktory

Kurz koruny vůči euru je významnou položkou pro podnikatele spolupracující se zahraničními firmami zejména z důvodů nakupování technologií na evropském trhu, a proto posilování koruny z pohledu společnosti je výhodou z hlediska nákupu technologií.

Končící ekonomická krize a ožívování trhů má pozitivní dopad na zvyšování poptávky a to jak ze strany odběratelů, tak ze strany zákazníků.

Od 1. 1. 2011 platí novela vyhlášky v provádění Intrastatu, což je statistický systém určený ke sběru a zpracování dat za účelem sledování obchodu se zbožím mezi členskými státy EU, kde jedna z nejdůležitějších změn je, že předávání výkazu bude probíhat pouze elektronicky a s tímto nařízením se mění i vzor tiskopisu výkazu.

S pomocí financování z ESF fondů je pro společnost vypracován projekt v oblasti změny firemní kultury a stylu řízení společnosti společně se vzděláváním, který bude probíhat v časovém horizontu 3 – 5 let. Cílem projektu je tedy změna z řízení intuitivního na procesní řízení společnosti.

2.2.4. Politické faktory

Politické faktory, vyjma změny DPH a případně spotřebních daní, které mohou hýbat koupěschopností obyvatelstva, nemají na společnost významný vliv. Vláda se navíc prozatím jeví jako stabilní – její chování a zacílení na reformy je tedy předvídatelné.

Ačkoli politická situace v zahraničí je v současné době velmi vypjatá a regionální nestabilita některých zemí, především na středním východě je vyhrčená, zahraniční partneři jsou zejména ze zemí jako je Španělsko, Itálie, Německo, Velká Británie či Slovensko, a ty se jeví jako velmi stabilní.

2.2.5. Technologické faktory

Technologické faktory vycházejí jednoznačně ze spolupráce společnosti se zahraničními partnery, kde nově využívané technologie můžeme rozřadit do následujících skupin:

- Výtahové komory – tento typ výdeje zboží se zejména využívá při podávání skleněného zboží, knih, chlazených potravin nebo křehkých pochutin
- Kontrola ID – tento způsob je využíván při kontrole věku u cigaretových automatů, případně automatů prodávající alkoholické nápoje
- Bezhotovostní platební systémy – jejich využití umožňuje snadné objednání, rychlou inventarizaci, možnost využití cíleného bonusového programu na zákazníka nebo například spojením projektů „Plzeňská karta“ nebo v kooperaci s výrobcí mobilních telefonů a technologií NFC (Near Field Communication) zřízení elektronické peněženky.
- Telemetrie – možnost online kontroly zařízení a nastavení informačních zpráv při nízkém stavu zásob je velmi výhodný způsob pro optimalizaci kontrol a dodávek zboží do automatů.

2.3. Porterův model konkurenčního prostředí

2.3.1. Vyjednávací síla odběratelů

Odběratelé společnosti se dají rozdělit do dvou skupin:

- Vendingoví operátoři – subjekty, které odebírají zařízení, platební systémy nebo suroviny.
- Přímí odběratelé – manažerské kuchyňky, školy, úřady, nemocnice či jiné veřejné prostory, kteří požadují v určitých intervalech dodávky surovin.

V současné době kupní síla zákazníků není nijak výrazně silná z důvodu doznívající ekonomické krize, avšak jedná se přirozeně přechodný stav. Silní zákazníci sice mohou tlačit jak na prodejní ceny produktů, tak na ceny poskytovaných služeb, ale se silící konkurencí se vyjednávací síla odběratelů snižuje.

2.3.2. Vyjednávací síla dodavatelů

S ohledem na zaběhlé vazby mezi odběrateli a dodavateli, nelze předpokládat výrazné změny z hlediska změny dodavatelů. K těmto změnám může dojít v případě uvádění nových technologií na trh, kdy s nimi mohou přicházet i noví dodavatelé. Toto je možné brát v úvahu jen v dlouhodobém horizontu. Vyjednávací síla dodavatelů kopíruje křivku odběrů.

Někteří dodavatelé navíc dokážou ocenit platební morálku společnosti a to způsobem určitých benefitů či slev, kdy odběry nemusí být podmíněny velikostí, ale cení se pravidelnost odběrů.

2.3.3. Hrozba nových konkurentů

Reálnost vstupu nových konkurentů na trh je závislá na existujících bariérách vstupu do odvětví. Platí, že tyto bariéry jsou zejména náročné na kapitál a případný nový konkurent by musel disponovat vysokým kapitálem.

Základní bariéry vstupu do odvětví:

- Tradice a dobré jméno u zákazníků - vybudovaná síť zákazníků.
- Při přechodu k jinému dodavateli, mohou vznikat zvýšené náklady z důvodu nových vazeb a vztahů. Jednodušší je tedy neměnit zaběhnuté zvyklosti a takováto situace vyhovuje stávajícím firmám.
- Nový výrobce či dodavatel musí vynaložit zvýšené náklady na své uvedení na trh, vysoké náklady jsou i na samotný rozjezd firmy.

V současné době nehrozí do této oblasti masový vstup nových firem, také z důvodů způsobených ekonomickou recesí, ve které byl zaznamenán pokles poptávky po službách a produktech, jelikož klesala kupní síla a společnosti se snažily neustále snižovat náklady - šetřit.

Avšak existuje část trhu, zejména u distribuce nízkonákladových surovin, kde se požadavky na kvalitu snižují, kde svou příležitost může vycítit lokální podnikavý člověk, který svou krátkodobou činností dlouhodobě nabourá ceny.

2.3.4. Hrozba substitutů

Hrozba substitutů může být vnímána ve dvou rovinách. První je z oblasti surovin, konkrétně balených výrobků, které jsou v ceně za jednotku levnější, avšak ne zcela v některých případech reprezentativní. Druhá část je v oblasti bufetového stravování, kterého větší společnosti nebo místa s velkým počtem průchozích lidí využívají.

2.3.5. Rivalita mezi stávajícími konkurenty

Každá společnost má v tržním prostředí svého konkurenta, kterého se snaží předčit a je tedy vhodné své konkurenty a jejich možnosti znát a sledovat.

Mezi významné konkurenty patří následující společnosti:

- Delikomat s. r. o.,
- Dalmayr Kaffee - Alois Dallmayr Automaten-Service s. r. o.,
- Selecta – Automaty Servis Selecta s. r. o.,
- Coca Cola HBC.

Konkurence v tomto odvětví je vysoká, i když růst odvětví je pomalý. Dnes je tomu tak, že existují určité bariéry vstupu na trh, který začíná být pomalu nasycen.

Teoretická východiska práce

3. Neuronové sítě

„Umělá neuronová síť je paradigma zpracovávání informací, inspirované biologickými nervovými systémy zpracování informací, jako je mozek. Klíčovým prvkem tohoto paradigmatu je nová struktura systému zpracovávání informací. Skládá se z velkého počtu vzájemně propojených prvků (neuronů), pracujících společně na řešení specifických úloh. Umělá neuronová síť se stejně jako lidé učí z příkladů.“²


Christos Stergiou a Dimitrios Siganos

3.1. Biologický neuron

Ve čtyřicátých letech 19. století se český fyziolog Jan Evangelista Purkyně zasloužil o objev, při kterém identifikoval elementární jednotku nervové soustavy – nervovou buňku nazývanou neuron viz Obrázek 2. Neuron z morfolického a jemu podřízenému histologickému hledisku (nauka o tkáni) je základní jednotkou nervové tkáně. Tato jednotka je schopna přijímat, vést, zpracovávat a odpovídat na signály z vnitřního i vnějšího prostředí a tímto zpracováváním informací podporuje schopnost organismu na tyto signály reagovat.

Neuron je tvořen buněčným tělem (perikaryon, neurocyt, soma) a cytoplasmatickými výběžky, které jsou dvou typů – krátké dendrity a dlouhé axony. Dendrity jsou výběžky, které přijímají vstupní informace. Počet dendritů je u různých nervových buněk odlišný. V některých případech mohou zcela chybět (unipolární dendrity), případně má neuron jeden dendrit (bipolární neurony). Častějším případem je stav, kdy neuronová buňka má větší množství počet dendritů (multipolární neurony) a v některých případech se jedná i o několik tisíc výběžků. [19]

² FANTA, J., Psychologie, algoritmy a umělá inteligence na kapitálových trzích, s. 94



Obrázek 2. Biologický neuron

(Zdroj: Neuron [19] – pozměněn)

Zatímco počet dendritů je u různých nervových buněk odlišný, axon je vždy právě jeden. Axon je dlouhý výběžek ne nervové buňce a pomocí axonu se přenáší vzruch z jednoho neuronu na dendrit druhého.

Neurony spolu komunikují pomocí struktur zvaných synapse. Synapse je spojení dvou neuronů sloužící k předávání vzruchů. Neurony se v synapsích přímo nedotýkají, je mezi nimi synaptická štěrbina. Synapse převádějí informaci pouze jedním směrem, nedochází však k převodu jednotlivých vzruchů, ale k přenosu dojde vždy až po sumaci vzruchů z několika axonů případně sumací rychle po sobě následujících vzruchů z jednoho axonu.

Samotný přenos informací je chemicko-elektrický proces. Neurony jsou obklopeny rozpuštěnými ionty vápníku, sodíku, draslíku a chlóru. Sodík a vápník jsou schopny vytvářet aktivní neuronové odezvy, které jsou nazývané akčními potenciály – nervové impulsy. Ionty draslíku se nacházejí převážně uvnitř nervové buňky a ionty sodíku se soustřeďují na povrchu těla neuronu. Vznik a přenos nervového impulsu způsobuje záměna iontů draslíku a vápníku vyvolaná změnou přípustnosti buňkové membrány. Jakmile jsou nervové impulsy dopravené do synapsí, jsou přepuštěny do dendritů, což způsobuje vznik elektrické reakce. Takováto elektrická reakce může být buďto zesilující (excitační) anebo utlumující (inhibiční). Velikost signálu v dendritu je proporcionálně přiměřená frekvenci, se kterou impulsy dosáhnou synaptického spojení. Efekt zvyšování, případně snižování, elektrického impulsu je realizován uvnitř neuronu.

Jakmile tento potenciál dosáhne určité úrovně, buňka se vybudí a vyšle signál do axónu, ve kterém se rozvětví a po určité době dosáhne synaptického spojení s jinými buňkami.³


3.2. Umělý neuron

V roce 1943 neuropsycholog W. S. McCulloch a matematik W. Pitts dokázali za pomoci kombinace znalostí z neuropsychologie a matematické logiky popsat modely umělých neuronů.⁴

A ačkoliv biologické neurony neuronové sítě mají v porovnání mnohem složitější složení a strukturu než neurony umělé, vychází z nich princip fungování umělých neuronů. Vstupy neuronů, po kterých přicházejí informace, které jsou ohodnoceny synaptickými váhami. Nejjednodušší model umělého neuronu sečte všechny vstupy vážené odpovídajícími váhami a výsledek vloží do prahové funkce. Poté co je prahová funkce odečtena se aktivační funkcí signál transformuje na signál výstupní a je předáván dále například neuronům ve skryté, případně výstupní vrstvě. Tento model je matematicky:

$$Y = S\left(\sum_{i=1}^N (w_{nj}x_n) + \theta\right)$$

Graficky lze tento model matematicky popsaného neuronu znázornit tak, jak je uvedeno na Obrázku 3.



Obrázek 3. Graficky zobrazený matematický neuron
(Zdroj: MathWorks – Neural network toolbox [15])

³ MARČEK, Milan; PANČÍKOVÁ, Lucia; MARČEK, Dušan. Ekonometria a soft computing, s. 152

⁴ ARBIB, Michael. The handbook of brain theory and neural networks, s. 26

- x_n znázorňují vstupy neuronu
- w_{nj} znázorňují synaptické váhy neuronu
- Θ znázorňuje prahovou hodnotu neuronu
- $S(x)$ popisuje přenosovou (aktivační) funkci neuronu
- Y je výstupem neuronu

V biologickém neuronu práh Θ označuje prahovou hodnotu aktivace neuronu. Tzn. je-li $\sum_{i=1}^N (w_{nj}x_n)$ menší než práh, neuron je v pasivním stavu.

3.3. Modely neuronových sítí⁵

Jako téměř ve všech vědních disciplínách existuje i v oblasti neuronových sítí velká část modelů určených pro praktickou aplikaci a mezi nejpoužívanější patří:

- **Lineární model**
- **Vícevrstvé neuronové sítě**
- **Radial Basis Function**
- **Generalized Regression Neural Network**
- **Probabilistický model neuronové sítě**
- **Kohonenova neuronová síť**

3.3.1. Lineární model

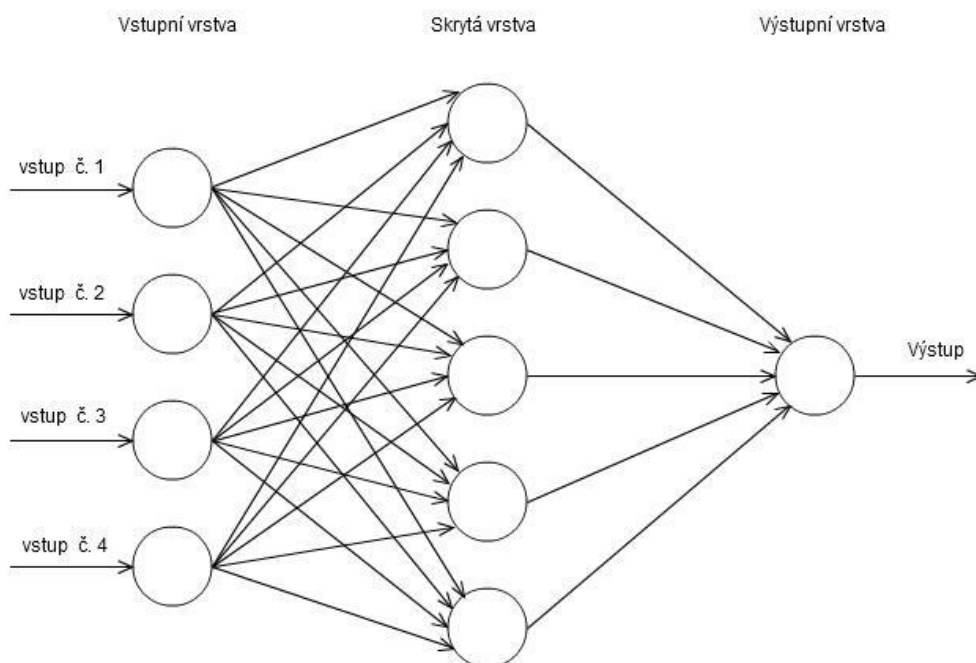
Lineární model je základním modelem neuronové sítě. Síť je složena pouze ze dvou vrstev a transformační a aktivační funkce jsou lineární.

3.3.2. Vícevrstvé neuronové sítě

Nejjednodušší model neuronové sítě nazývaný perceptron, který jako první namodeloval F. Rosenblatt, má pro své využití značná omezení. Jeho rozšířením na vícevrstevný perceptron získáváme mnohem širší možnosti využití. Vícevrstvá neuronová síť je tvořena minimálně třemi vrstvami – vstupní, výstupní a minimálně jednou vrstvou skrytou.

⁵ FANTA, J. Psychologie, algoritmy a umělá inteligence na kapitálových trzích, s. 104 - 106

Vstupem takovéto neuronové sítě je vstupní vrstva, kde počet neuronů odpovídá velikosti vstupního vektoru. Následuje skrytá vrstva, která nemusí být pouze jedna a volba počtu skrytých vrstev je libovolná a na poslední skrytou vrstvu je napojena vrstva výstupní, ve které počet neuronů ve výstupní vrstvě, obdobně jako u vrstvy vstupní, odpovídá velikosti výstupního vektoru. Všechny vrstvy jsou spojené pouze směrem dopředu – kombinace vstup/výstup viz Obrázek 4.



Obrázek 4. Topologie neuronové sítě 4-5-1
(Zdroj: vlastní)

Při takovéto kombinaci vrstev je nutné brát v potaz návrh jednotlivých vrstev a zvolení správné topologie, jelikož správnost návrhu má vliv na kvalitu řešení. Někdy se topologie neuronových sítí značí čísly, kde například označení 4-5-1 popisuje neuronovou síť se 4 vstupními neurony, jednou skrytou vrstvou se 4 neurony a výstupní vrstvou s 1 neuronem

3.3.3. Radial Basis Function

Radial Basis Function je architektura neuronové sítě, která má vstupní a skrytou vrstvu s radiálními umělými neurony a s lineární výstupní vrstvou. Vrstva s radiálními neurony má exponenciální aktivační funkci. Trénink sítě RBF bývá obvykle rychlejší než v případě jiných architektur sítí. Výsledná síť po tréninku je však obvykle pomalejší

v porovnání s analogicky řešenými příklady. Tento druh sítí je využíván na vyrovnávání, aproximaci a interpolaci méně strukturovaných problémů s rozptýlenými daty.

3.3.4. Generalized Regression Neural Network

Generalized Regression Neural Network je model, jehož architektura je určena pro řešení úloh, ve kterých jsou data řídká a rozptýlená s kontinuálními výstupy. Obvykle pracuje se čtyřmi vrstvami – vrstva vstupní, vrstva s radiálními centry, vrstva s regresními neurony a vrstva výstupní. Radiální centra označují středy shluků dat, které bývají nastavovány před užitím trénovacího algoritmu. Regresní vrstva neuronů obsahuje lineární neurony počítající buďto požadovaný regresní výstup nebo se jedná o neurony počítající hustotu pravděpodobnosti.

3.3.5. Probabilistický model neuronové sítě

Tento model je analogií modelu předchozího (GRNN) a je určen pro klasifikační úlohy. U těchto sítí je počet umělých neuronů ve skryté vrstvě roven minimálně počtu trénovacích dat. U tohoto modelu dále může být nadefinována další vrstva nazývaná maticí ztrát. Tato matice se užívá k vážení pravděpodobností známými náklady nesprávné klasifikace k dosažení minima rozhodovacích chyb, a to tehdy, existuje-li reálné nebezpečí, že nesprávně klasifikované případy mohou způsobit vážné problémy.

3.3.6. Kohonenova neuronová síť


Kohonenova neuronová síť je síť, která je založená na algoritmu shlukové analýzy a není potřeba přítomnosti přenosové funkce. Kohonenova neuronová síť má pouze dvě vrstvy – vstupní a výstupní. Jedinou operaci, kterou neurony provádějí, je výpočet odchylky předloženého vzorku od vzoru uloženého ve vahách daného neuronu. Navíc každý neuron ve výstupní vrstvě je přímo výstupem a počet výstupů je tedy roven počtu neuronů.

3.4. Přenosové (aktivační) funkce⁶

Úkolem aktivační funkce je převést vstupní hodnotu na výstupní. Existuje mnoho typů těchto funkcí. Ve své podstatě je můžeme dělit ze dvou hledisek a to na diskrétní/spojité nebo na lineární/nelineární. Volba aktivační funkce závisí na typu řešené úlohy nebo dle typu umístění ve vrstvách, jelikož při využívání skrytých vrstev neuronových sítí se aktivační funkce volí jiné než například ve vrstvě výstupní.

Nejvyužívanější aktivační funkce:


- **hardlim** – skoková přenosová funkce (viz Obrázek 5.), nejjednodušší typ funkce, která může nabývat pouze hodnoty 0 nebo 1. Tato funkce má tzv. separabilní charakter, díky němuž může jednoduše například rozdělovat datový soubor do dvou částí. Matematický popis funkce: $a = \text{hardlim}(n) \begin{cases} n = 0 & \text{pro } a < 0 \\ n = 1 & \text{pro } a \geq 0 \end{cases}$



Obrázek 5. Skoková aktivační funkce

(Zdroj: MathWorks – Neural network toolbox [15] - pozměněn)

- **purelin** – lineární aktivační funkce (viz Obrázek 6.), která hodnotu na vstupu převádí na výstup a je matematicky vyjádřena jako $a = \text{purelin}(n) = n$,




Obrázek 6. Lineární aktivační funkce

(Zdroj: MathWorks – Neural network toolbox [15] - pozměněn)

⁶ MathWorks – Neural Network Toolbox [15]


- **logsig** – Log-Sigmoida (logistická funkce) viz Obrázek 7., nelineární přenosová funkce, jejíž výstupní hodnota může nabývat hodnot v rozmezí 0 až 1. Matematický popis funkce: $\text{logsig } n = \frac{1}{1+e^{-n}}$



Obrázek 7. Logistická aktivační funkce

(Zdroj: MathWorks – Neural network toolbox [15] - pozměněn)

- **tansig** – Tan-Sigmoida, je nelineární funkce – hyperbolická tangenta (viz Obrázek 8.), jejíž výstupní hodnota nabývá hodnot v rozmezí -1 až 1. Matematický popis funkce: $\text{tansig } n = \frac{e^n - e^{-n}}{e^n + e^{-n}}$



Obrázek 8. Hyperbolická tangenta (aktivační funkce)

(Zdroj: MathWorks – Neural network toolbox [15] - pozměněn)

3.5. Učení neuronových sítí⁷

V biologických neuronových sítích jsou informace uloženy v dendritech. U umělých neuronových sítí je tato vlastnost zajištěna za pomoci vah (weights). Při výpočtu vah neuronových sítí je u učení (tréninku) cílem optimalizace nalezení globálního minima chyby pro daný parametr úlohy. Chyba E (*error*) je rozdíl mezi hodnotou vstupní závislé proměnné n (*target*) a vypočítané hodnoty proměnné o (*actual*). Nejprve se tedy provede výpočet výstupů na základě hodnot na vstupech a vah a následně je prováděn výpočet chyby E , která je definována vzorcem $E = \sum (n_i - o_i)^2$, kde n_i je i -tá hodnota na výstupu a o_i je i -tá očekávaná hodnota. Výpočet je prováděn přes všechny výstupy a v každém cyklu. Rozdíl je poté využíván k zpětnému výpočtu vah a proces se opakuje, než chyba E konverguje k zadavatelem akceptovatelné hodnotě. Takovéto učení je označováno jako řízené učení.

Druhým typem tréninku sítě je tzv. neřízené učení, které patří také mezi optimalizační úlohy a jehož principem je identifikace shluků dat s minimální vzdáleností od centra shluku.

Mezi nejvyužívanější trénovací (učicí) algoritmy a postupy patří zejména tyto:

- **Back-propagation** – jeden z nejužívanějších algoritmů pro trénování neuronových sítí. Algoritmus provádí postupné kroky přibližující chybu lokálnímu minimu, které je teoretickým řešením, reprezentující nejmenší možnou chybu.
- **Levenberg-Marquardtův algoritmus** – jeden z nejčastěji používaných algoritmů pro optimalizaci, který dosahuje vysoké rychlosti nalezení výsledku na základě Lavenberg-Marquardtově optimalizaci.
- **Quasi-Newtonův algoritmus,**
- **Quick Poropagation algoritmus,**
- **Kohonenova adaptace** - princip učení Kohonenovy neuronové sítě vychází ze shlukování neuronů,
- **Volba vstupů pomocí genetických algoritmů.**

⁷ DOSTÁL, Petr. Pokročilé metody analýz a modelování v podnikatelství a veřejné správě, s. 45 - 46

Problémem při trénování neuronových sítí je algoritmus, který by měl být použitelný na obdobné úlohy – generalizovatelný. V případě ztráty možnosti generalizace s ohledem na data při řešení úlohy se neuronová síť označuje jako přetrénovaná (overtrained). Pokud k tomuto jevu dochází v průběhu učení tak síť je označována jako přeučená (overlearned).

V případě, že je funkce příliš jednoduchá pro zachycení nelineárních vztahů mezi daty nastává opačný jev anglicky označovaný jako undertraining případně underlearning.

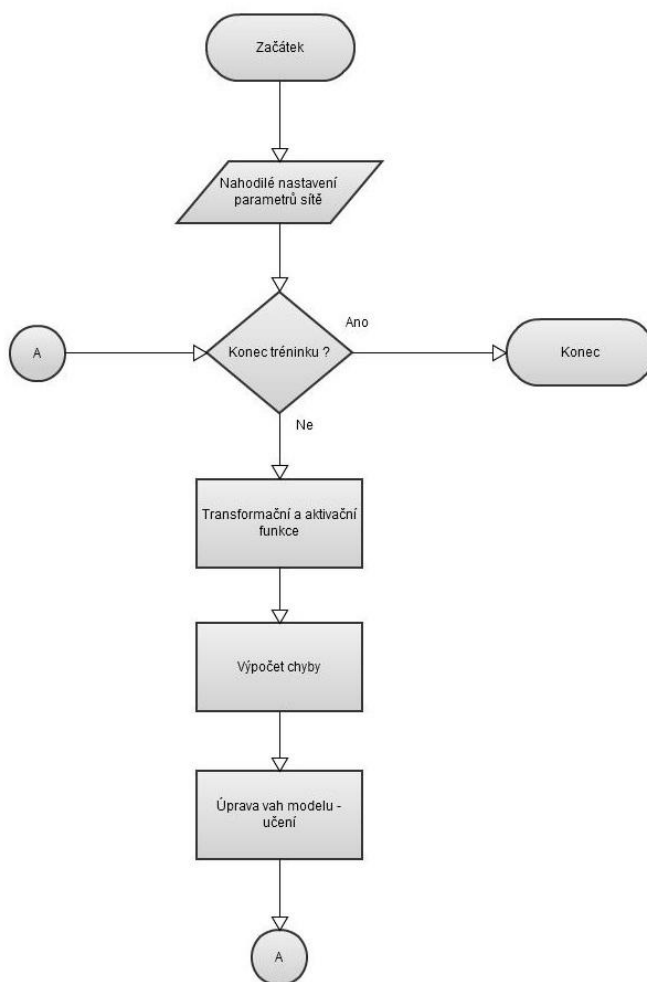
Existuje několik postupů jak se těmto problémům vyhnout:

- Přidáním šumu do trénovacích dat
- Správně zvolení počtu umělých neuronů a počet vrstev neuronové sítě
- Monitorování průběhu trénování neuronové sítě – způsob, kdy vyčlením určité procento dat označovanou jako ověřovací data (validation set). Ověřovací data neupravují váhy modelu neuronové sítě a fungují jako signál upozorňující uživatele, že trénovací algoritmus probíhá příliš dlouho a neuronová síť je vzhledem k datům příliš komplexní. Ukončení trénování dat neuronové sítě nastává v momentě, kdy chyba ověřovací množiny dat začíná růst, a to i v případě, kdy chyba trénovací množiny dat klesá.
- Weight Regularitization – jedná se o úpravu trénovacího algoritmu, který může být popsán jako penalizace velkých vah.
- Zvolení ukončovací podmínky tréninku – trénování neuronové sítě je možno ukončit například, když chyba klesne pod určitou zadanou hodnotu nebo, když se chyba po určitý počet epoch (iterací) nemění.

3.6. Obecné schéma práce neuronové sítě⁸

Trénování vícevrstvé sítě s řízeným učením funguje v následujících krocích (viz Obrázek 9.):

1. Nahodilé nastavení volných parametrů neuronové sítě (vah),
2. Průběh dat sítí: transformační a aktivační přenosová funkce
3. Výpočet chyby porovnáním aktuálního výstupu s empirickým výstupem (target)
4. Zpětná úprava parametrů (vah) modelu neuronové sítě
5. Vyhodnocení podmínky:
 - Ano -> konec tréninku
 - Ne -> opakování kroků 2 - 5



Obrázek 9. Obecné schéma práce neuronové sítě
(Zdroj: FANTA [3])

⁸ FANTA, J., Psychologie, algoritmy a umělá inteligence na kapitálových trzích, s. 109

Shrnutí

Umělé neuronové sítě jsou nedokonalým modelem sítí biologických a základem využívaným v oboru umělé inteligence. Sítě se skládají z neuronů, které se nacházejí v různých vrstvách a jsou vzájemně propojeny a za pomoci různě zvolených aktivačních funkcí si předávají informace. Každý takovýto neuron může mít libovolné množství vstupů, ale právě jeden výstup. Takto nadefinovaná umělá neuronová síť se stává využitelnou po natrénování (učení) sítě, kdy jednotlivým vstupům jsou přepočítány váhy.

Díky těmto specifikacím mají neuronové sítě využití zejména v úlohách se složitým matematickým popisem, případně při neurčitých, neúplných informacích nebo v případech, kde může mít podstatnou roli náhoda. Jsou tedy vhodné pro modelování složitých, často nevratných, strategických rozhodnutí.⁹

Výhody neuronových sítí spočívají zejména ve schopnosti učit se nebo možnosti adaptivního návrhu sítě. Další výhodou je možnost zachycení nelineárních vztahů a řešení velmi složitých úloh.

Mezi nevýhody patří zejména obtížné definování optimální topologie neuronových sítí, protože neexistují základní pravidla či koncepty při využití pro tvorbu libovolných aplikací a tedy i při využití stejných vstupních dat u různých neuronových sítí získáme různé výsledky (například při využití různých softwarových nástrojů). Neuronové sítě se dále nedají využívat u exaktně zadaných řešení různých problematik a u problematik vyřešených je velmi obtížné popsání způsobu nalezení řešení.

Využití neuronových sítí může nalézt uplatnění v mnoha oblastech od robotiky, přes lékařské aplikace (určování diagnózy neurologických onemocnění u dětí) [25], využití v nástrojích business intelligence, analýze časových řad a jejich případné predikce aj. Nutno je však brát v potaz, že neuronové sítě by se neměly výhradně preferovat oproti jiným matematickým nebo analytickým metodám, protože vždy záleží typu úlohy, která je dána k řešení.

⁹ DOSTÁL, Petr. Pokročilé metody analýz a modelování v podnikatelství a veřejné správě, s. 42

4. Kapitálový trh

Kapitálový trh jakožto podmnožina trhu finančního je prostředí, ve kterém dochází ke směně kapitálu, tedy prostředků využívaných ke tvorbě zisku prostřednictvím cenných papírů a jejich derivátů. Cenné papíry jsou emitovány podniky a finančními institucemi, a jedná-li se o veřejně obchodovatelné papíry, jsou následně nabízeny na burze. Jejich prodejem tyto podniky, případně instituce, získávají prostředky pro financování vlastní činnosti. Cenné papíry jsou nakupovány investory (banky, fondy, fyzické osoby) na burzách, z důvodu vidiny zhodnocení vynaložených volných prostředků [13].

4.1. Vznik a vývoj kapitálových trhů¹⁰

Dnešní podoba trhů je výsledkem dlouhodobého vývoje trvajícím již několik staletí a reflektuje aktuální potřeby ekonomiky a v průběhu let se neustále zdokonaluje.

Historický vývoj ve světě neprobíhal ve všech zemích současně a stejným způsobem. Tempo a trendy tohoto vývoje diktovaly země s nejvyspělejší ekonomikou v dané době, a které následovaly a z jejich vývoje těžily země méně vyspělé. Středověké kapitálové trhy začaly vznikat společně s rozvojem obchodu a řemesel. Tyto trhy byly ideálním místem pro setkávání obchodníků a bankéřů, kde docházelo k prodeji zboží a to jak lokální výroby tak dovezeného. Další příležitostí bylo uzavírání půjček za pomoci směnky a směna různých druhů měn.

4.1.1. Vznik a vývoj burzovníctví

Existují minimálně dvě teorie, popisující, jakým způsobem vzniklo slovo „burza“.

¹¹První teorií je, že slovo burza pochází z latinského slova „bursa“, které v překladu znamená peněženka, měšec, váček. ¹²Druhá teorie popisuje, že název je odvozen od jména rodiny bankéře Van der Buerse, před jehož domem v Bruggách se lidé scházeli na jednom z největších středověkých trhů. V Belgii vznikla také burza v Antverpách. Roku 1531 byla vybudována první burzovní budova. U prvotních forem burzy šlo o neformální setkávání obchodníků a formálně se nikdo nestaral o její organizaci. Účelem prvních burzovních obchodů byly jen směnky a mince a zhruba od poloviny 16. století se předmětem obchodu pomalu začínalo stávat také skutečné zboží. V období

¹⁰ PAVLÁT, Vladislav. Kapitálové trhy, s. 51

¹¹ Počátky burzovníctví [20]

¹² PAVLÁT, Vladislav. Kapitálové trhy, s. 52

průmyslové revoluce a rozvoji kapitalismu (18. – 19. století) vzniklo po celém světě velké množství burz jako např. známá burza v New Yorku na Wall Streetu (1792) nebo v Praze (1871).

Ve dvacátém století s rozvojem výpočetní techniky a informačních technologií klesá význam lokálních burz a vzrůstá význam burz mezinárodních. Tento vývoj může být popsán termínem globalizace kapitálových trhů.

4.2. Faktory ovlivňující rozhodování investora¹³

Mezi velmi významné faktory ovlivňující rozhodování potencionálních investorů patří předpokládaný výnos investice ruku v ruce s jejím rizikem. Důležitým faktorem je také likvidita investice. Tyto faktory je nutno zvolit způsobem, který je pro investora přijatelný.

- Výnos investice – tato veličina často odpovídá v absolutním měřítku zisku (výnosu) a je definován jako rozdíl mezi výnosem a investovanými prostředky. V relativním měřítku je míra zisku vyjádřena poměrem zisku k celkovým nákladům a je označována jako výnosové procento,
- Riziko investice – riziko je dáno stupněm nejistoty, který je spojen s očekávaným výnosovým procentem. Je nutno brát na zřetel, že u různých typů obchodovatelných položek, které mají stejné očekávané výnosové procento, mohou mít různé míry rizika,
- Likvidita investice – tento parametr udává, jak rychle lze investici přeměnit zpět na hotové prostředky,
- Zlaté pravidlo investování – zlaté pravidlo investování v sobě zahrnuje všechny tři výše uvedené faktory a to způsobem, kdy dosahujeme maximálního výnosu při minimálním riziku s možností nejrychlejší přeměny na hotové peníze. V reálném světě však takový druh investice neexistuje a je nutno snížit (optimalizovat) nároky na jednotlivé faktory.

¹³ PAVLÁT, Vladislav. Kapitálové trhy, s. 129

5. Predikce a technická analýza

5.1. Predikce časových řad¹⁴

Časová řada je definována jako určitá řada hodnot konkrétního ukazatele uspořádaná z hlediska přirozené časové posloupnosti. Zároveň je nutné, aby věcná náplň daného ukazatele a také jeho prostorové vymezení byly shodné v celém sledovaném časovém úseku.¹⁵ Z matematického hlediska můžeme predikci zapsat jako posloupnost hodnot $x_1, x_2 \dots x_n$, kde n udává počet hodnot časové řady a prvek x odpovídá hodnotě veličiny v daném čase.

Pokud bychom časovou řadu dekomponovali, zjistíme, že obsahuje trendovou, sezónní, cyklickou a náhodnou složku, kde původní časovou řadu lze vyjádřit pomocí součtu jednotlivých složek – aditivní dekompozice.

Trendová složka popisuje obecnou tendenci vývoje sledovaného ukazatele v čase, sezónní složka popisuje periodické změny v časové řadě, které se v určitých intervalech mohou opakovat, cyklická složka popisuje fluktuaci trendu, ve kterém se střídá fáze růstu a fáze poklesu, kde tyto fáze jsou důsledkem vnějších vlivů. Náhodná složka je tvořena náhodnými fluktuacemi v průběhu časové řady, které nemají rozpoznatelný systematický charakter a pokrývá tak chyby v měření údajů, které se mohou vyskytovat například u zaokrouhlování údajů.

¹⁶Predikce – slovo složené z latinských *prae* (před) a *dicere* (říkat) vyjadřuje jednoznačnou předpověď vycházející ze zjištěných či experimentálně ověřených faktů, hypotéz nebo teorií. Takového odhadu budoucího stavu či chování se využívá v mnoha vědních oborech. Ve finanční a ekonomické oblasti se predikce vývoje využívá při odhadování cen akcií, komodit, indexů, apod.

Za základní odhad hodnoty můžeme považovat extrapolaci, je využívána v numerických metodách a označuje stav, kdy se snažíme matematicky nalézt hodnotu funkce mimo interval známých hodnot. Neznámé hodnoty můžeme taktéž hledat, v případech neúplné časové řady, vně intervalu, kdy dochází k tzv. interpolaci.

¹⁴ DOSTÁL, Petr. Pokročilé metody analýz a modelování v podnikatelství a veřejné správě, s. 170

¹⁵ KROPÁČ, J. Statistika B: jednorozměrné a dvourozměrné datové soubory, regresní analýza, časové řady, s. 114

¹⁶ Predikce [21]

K predikci můžeme využít také neuronové sítě, kde tyto sítě mají schopnost se trénovat a učit na historických datech a tak objevit skryté nelineární vlastnosti. Nevýhodou tohoto řešení je, že je nemožné odhadnout velikost chyby při předpovědi a neexistuje universální model.

5.2. Technická analýza

Technická analýza je využívána k předpovědi budoucích cenových pohybů nebo objemech na základě historických dat čímž se výrazně liší od fundamentální analýzy. Cílem technické analýzy je přibližné určení budoucího vývoje cen, zejména je využívána díky své schopnosti určit konec a případného otočení trendu a snižuje takhle procento chyby při předpovědi.

Technická analýza vychází z výpočtů technických ukazatelů, které mohou poskytovat informace o objemech obchodů, hybnosti trhu apod. Většina ukazatelů je odvozena na základě historických dat tzn., že informace dostáváme se zpožděním.

Mezi nejvýznamnější technické ukazatele, mj. využívané v diplomové práci, patří zejména tyto:

a) Klouzavé průměry

Klouzavé průměry je možné využít pro jednoduché odhalování trendu, který se počítá jako průměr stejného počtu za sebou jdoucích období. Klouzavé průměry slouží zejména k vyhlazení křivky časové řady a následně tak určit trend či změnu trendu.

Existují čtyři základní typy klouzavých průměrů:

- Jednoduchý klouzavý průměr,
- Exponenciální klouzavý průměr,
- Vyhlazený klouzavý průměr,
- Lineárně vyvážený klouzavý průměr.

Pro potřeby diplomové práce jsou využívány první dva typy klouzavých průměrů.

b) MACD (Moving Average Convergence Divergence)¹⁷

Indikátor MACD popisuje sbíhavost a rozbíhavost mezi dvěma exponenciálními klouzavými průměry. Nastavení velikosti těchto dvou exponenciálních klouzavých průměrů by mělo být principiálně svázáno s tržními cykly daného investičního nástroje.

¹⁷ MACD: Téměř „zlatý grál“ [14]

c) ROC (Rate Of Change)¹⁸

Tento indikátor je jedním z nejpoužívanějších indikátorů technické analýzy popisující sílu a rychlost trendu. Jeho hlavní výhodou je jednoduchost výpočtu, kde vzorec výpočtu je $ROC = \frac{cena(t) - cena(t-d)}{cena(t-d)}$, kde $cena(t)$ je aktuální uzavírací cena a $cena(t-d)$ je uzavírací cena o d dní zpět.

d) RSI (Relative Strength Index)¹⁹

Index relativní síly měří vnitřní sílu investičního nástroje. Tento indikátor se využívá pro identifikaci přenakoupeného a předprodaného trhu a zároveň také pomáhá potvrdit trend a určení jeho směru. Indikátor nabývá hodnot v rozmezí $<0;100>$, kde důležitá pásma jsou v rozmezí $<0;30>$ a $<70;100>$. První rozmezí popisuje předprodaný trh a naznačuje možnost budoucího růstu hodnoty investičního nástroje. Druhé rozmezí naopak popisuje přednakoupený trh, kde je očekáván pokles hodnoty investičního nástroje.

e) Stochastické oscilátory²⁰

Stochastický oscilátor je indikátor hybnosti, který popisuje umístění aktuální uzavírací ceny ve vztahu k rozpětí nejvyšší a nejnižší ceny v průběhu určité délky období. Indikátor nabývá obdobných hodnot jako RSI index s rozdílem, kdy dolní mez je stanovena hodnotou 20 a horní mez hodnotou 80. Údaje u dolní meze jsou považovány za předprodané a u horní za přednakoupené, avšak nejedná se o pravidlo. Hodnota investičního nástroje může i nadále růst, i když stochastický oscilátor překročil 80 a i nadále klesat, i když hodnota poklesla pod 20. Za nejvhodnější signály jsou považovány situace, kdy se oscilátor pohne z přednakoupené oblasti zpět pod hodnotu 80 a z předprodané oblasti zpět nad hodnotu 20.

¹⁸ Momentum (technical analysis) [18]

¹⁹ Index relativní síly [11]

²⁰ Indikátory technické analýzy [12]

f) **Bollingerova pásma**²¹

Bollingerova pásma umožňují sledovat volatilitu investičního nástroje a relativní cenovou úroveň v zadaném čase.

Bollingerova pásma jsou tvořena třemi křivkami:

- Horní pásmo, které je většinou rovno dvounásobku klouzavému průměru plus r krát standardní odchylkou
- Dolní pásmo, které je většinou rovno klouzavému průměru mínus r krát standardní odchylka
- Střední linie, která představuje klouzavý průměr uzavíracích kurzů investičního nástroje za zvolený počet obchodních dnů.

Poznámka: Nejčastěji se používá hodnota $r=2$, což označuje dvojnásobek klouzavého průměru.

Ve výsledku Bollingerova pásma mají za úkol naznačit, kdy je investiční nástroj relativně drahý nebo levný vzhledem k situaci na trhu. U tohoto indikátoru je nutné také dbát na to, že v případě dotyku nebo přetnutí horního či dolního pásma ve výsledku nemusí značit signál k nákupu nebo prodeji.

g) **Williams %R**²²

Tento indikátor je jedním z dalších z řady indikátoru popisující předprodané nebo předkoupené období. Velkou výhodou tohoto indikátoru je schopnost předvídat zvraty investičního nástroje několik dní předem. Indikátor je totiž schopen vytvořit vrchol a následně klesat ještě před tím než tento stav provede i cena investičního nástroje.

Princip oscilátoru tkví v porovnávání aktuální zavírací ceny s „high“ a „low“ cenami za posledních „x“ dní. Horní a dolní mez, indikující předprodanost nebo předkoupenost investičních nástrojů, jsou obdobně jako u stochastického oscilátoru stanoveny hodnotami 80 a 20.

²¹ Bollingerova pásma [7]

²² Indikátory technické analýzy [12]

6. Výpočetní systém Matlab

Pro praktickou část své diplomové práce jsem se rozhodl využít programového prostředí Matlab, což je prostředí určené pro vědeckotechnické výpočty, modelování, analýzu, simulace a mnoho dalších činností. Výpočetní systém Matlab se během uplynulých let stal celosvětovým standardem v oblasti technických výpočtů a simulací ve sféře vědy, výzkumu, průmyslu i v oblasti vzdělávání. Matlab poskytuje svým uživatelům nejen mocné grafické a výpočetní nástroje, ale i rozsáhlé specializované knihovny funkcí spolu s výkonným programovacím jazykem. Knihovny jsou svým rozsahem využitelné prakticky ve všech oblastech lidské činnosti. Za nejsilnější stránku Matlabu je považováno mimořádně rychlé výpočetní jádro s optimálními algoritmy, které jsou prověřeny léty provozu na špičkových pracovištích po celém světě.²³

²³ Matlab – Jazyk pro technické výpočty [16]

Vlastní návrhy řešení

Pro své potřeby v prostředí Matlabu využívám toolbox s názvem „Neural network time series tool“ (ntstool) určeného pro řešení dynamických neuronových sítí s možností predikce časových řad. Konkrétně se budu zabývat nelineárními autoregresními modely, zkráceně označovány jako NAR a NARX.

Prvním využívaným modelem je nelineární autoregresní model neuronové sítě (NAR), který dokáže predikovat na základě hodnot daných časovou řadou.


Druhý model je tzv. nelineární autoregresní model s vnějším (exogenním) vstupem (NARX), který dokáže predikovat z časových řad, ke kterým jsou přidávána na vstup další podpůrná data, a to z důvodu dosažení větší přesnosti výsledků neuronové sítě.

Oba dva modely získávají data uživatelem zvoleného indexu, akcie, komodity případně jiné obchodovatelné položky, které jsou dostupné na serveru <http://finance.yahoo.com/>, kde záznamy u některých položek mohou sahát i několik desítek let zpět. Data, která modely ve většině případu využívají k predikci, jsou Close hodnoty – tedy uzavírací ceny za jednotlivé dny, avšak na serveru jsou k dispozici všechny OHLC (Open, High, Low, Close) nebo také například Adjusted Close hodnoty.

7. Nelineární autoregresní model (NAR)


Jak již bylo zmíněno v předchozích kapitolách, nelineární autoregresní model neuronové sítě dokáže natrénovat a predikovat hodnoty časové řady pouze za pomoci historických hodnot vybraného ukazatele.

Máme-li tedy časovou řadu $y(t)$ a d hodnot dané řady můžeme model popsat matematicky následujícím způsobem $y(t) = f(y(t-1), \dots, y(t-d))$ a graficky znázornit způsobem viz Obrázek 10.



Obrázek 10. Základní schéma modelu NAR
(Zdroj: vývojové prostředí Matlab)

V konkrétních příkladech je grafické schéma NAR modelů odlišné od schématu základního a to z důvodu přesnějšího a detailnějšího zobrazení. Zobrazení navíc popisuje nastavení zpoždění, počet neuronů ve skryté vrstvě a také transformační funkce jednotlivých vrstev (viz Obrázek 11).



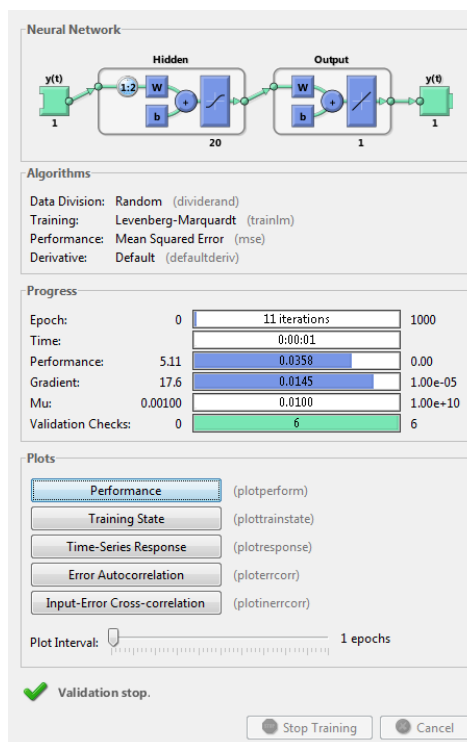
Obrázek 11. Zobrazení konkrétního NAR modelu s 20 neurony
(Zdroj: vývojové prostředí Matlab)

Proces modelování následně spočívá v tom, že na uživatelem vybraném investičním nástroji se síť natrénuje na vzorku tvořeného ze 70 procent dat, 15 procent je využito k validaci, která kontroluje generalizaci sítě s možností zastavení trénování, pokud se generalizovaný model již dále nevylepší, a zbylých 15 procent dat je určeno k nezávislému testování sítě. Data jsou do těchto tří výše zmíněných podskupin rozděleny náhodným výběrem.

Síť má dále nastaveno zpoždění (delay), které se způsobuje to, že si dle jeho velikosti ukládá určitý počet předchozích hodnot.


Následně je síť trénována za použití Levenberg-Marquardt algoritmu a chyba je měřena metodikou MSE (mean squared error) což je střední kvadratická chyba.

Při samostatném trénování na konkrétním testovacím modelu neuronové sítě se testování zastavilo v jedenácté iteraci (viz Obrázek 12), protože se chybu při validaci nepodařilo snížit na šest iterací (Validation Checks).



Obrázek 12. Trénování neuronové sítě u NAR modelu
 (Zdroj: vývojové prostředí Matlab)


Následně byl vygenerován graf za účelem zjištění, jestli nedošlo k přetrénování neuronové sítě. Graf, který je zobrazen na následujícím obrázku (viz Obrázek 13), ukazuje, že chybovost trénování, validace a testování postupně klesala až do páté iterace a jelikož do zmíněné páté iterace chybovost ani u jedné z křivek výrazně nevzrostla, můžeme konstatovat, že k přetrénování neuronové sítě nedošlo.



Obrázek 13. MSE graf
(Zdroj: vývojové prostředí Matlab)


Následující krok už vedl k samostatné predikci, a to způsobem, že bylo odstraněno zpoždění a takto nově vytvořená síť vracela stejné výsledné hodnoty jako původní neuronová síť, které však byly posunuty o velikost zpoždění směrem doleva.

Výsledná neuronová síť sloužící k predikci hodnoty na následující den pak vypadala následovně (viz Obrázek 14).




Obrázek 14. Predikční NAR model
(Zdroj: vývojové prostředí Matlab)

Pro zobrazení výsledků průběhu funkce neuronové sítě slouží následující grafy (Obrázek 15. a Obrázek 16.). První graf zobrazuje rozdíl mezi cílovou a výstupní hodnotou celého průběhu predikce a zobrazuje velikost predikční chyby v jednotlivých bodech.




Obrázek 15. Korelace časové řady a predikovaných hodnot
(Zdroj: vývojové prostředí Matlab)

Druhý graf vzniká překrytím vstupní (historické) časové řady a predikovaných hodnot s následným označením vývoje.



Obrázek 16. Zobrazení reálné a predikované hodnoty NAR modelu
(Zdroj: vývojové prostředí Matlab)

Obrázek 17. je přiblížením konce časové řady při zobrazení reálné a predikované hodnoty, na kterém je zřetelněji zobrazen odhad vývoje trendu na následující obchodní den.



Obrázek 17. Přiblížení predikce růstového trendu NAR modelu
(Zdroj: vývojové prostředí Matlab)

Z důvodu lepší přehlednosti a pro potřebu číselných podkladů je dále vygenerován slovní popis k dané predikci, který popisuje výsledky predikce následujícím způsobem (viz Obrázek 18).

```
-----
Predikovaná hodnota k (datum, položka, cena):
'31-Mar-2011' 'MSFT' [25.6622]
```

```
Následující obchodní den je očekávan rust ceny
```

Obrázek 18. Slovní popis výstupu NAR modelu
(Zdroj: vývojové prostředí Matlab)

Výsledky, které síť generovala, byly testovány a kompromitovány na vývoji kurzu akcií společnosti Microsoft za celý měsíc březen roku 2011. Jediný parametr sítě, který se při porovnávání hodnot měnil, byl počet neuronů (10, 20, 50 a 100), tedy ve výsledku byly porovnány čtyři NAR modely.

7.1. Vyhodnocení NAR modelu

Jelikož neexistuje obecný predikční model, za pomoci něhož se mohou nastavit parametry neuronové sítě, zvolil jsem, že jako jediný se bude měnit počet neuronů v síti. Síť byla postupně složena z 10, 20, 50 a 100 neuronů, na kterých probíhalo měření.

Měření probíhalo způsobem, kdy na začátku měsíce března jednotlivé sítě predikovaly odhad hodnoty akcií společnosti Microsoft a v případě, že hodnota byla predikována jako rostoucí, nakoupily se akcie za **\$100**. V průběhu měsíce se při rostoucí predikci akcie v případě jejich vlastnictví ponechaly nebo při prodeji v předchozím dni nakoupily v celkové hodnotě rovnající se zůstatku na virtuálním účtu.

Pokud hodnota byla predikována jako klesající, tak první den se akcie nenakupovaly, vyčkalo se na první den, který byl predikován jako rostoucí, a v průběhu měsíce se při predikci poklesu akcie prodaly.

Predikované výsledky byly zpětně porovnány s reálnými hodnotami. Z rozmezí odhadu konkrétních hodnot, které je naznačeno v Tabulce 1, vyplývá, že určit přesnou hodnotu je díky velkému rozptylu velmi obtížné. Avšak procentuálně vyjádřena úspěšnost, zejména u prvních dvou modelů v Tabulce 1, naznačuje, že mnohem jednodušší je odhadnout trend vývoje investičního nástroje. Zbylé dva modely se svými výsledky úspěšnosti jsou blízko hranici 50 procentům, které je možné docílit, v zlehčeném slova smyslu, hozením mince.

Počet neuronů	Rozmezí odhadu hodnoty [%]	Úspěšnost [%]	Výsledná bilance [\$]
10	0,015 – 4,733	73,9	103,16
20	0,052 – 2,051	65,2	105,24
50	0,067 – 5,32	52,2	99,67
100	0,147-11,947	56,5	100,5

Tabulka 1. Zhodnocení NAR modelů

V celkovém zhodnocení, tři ze čtyř modelů vykazují ziskovost a v případě, že bychom porovnali krátkodobou investici ve stejné výši do stejných akcií a celý měsíc neobchodovali, pak by výsledná hodnota byla \$97,17. Všechny modely by tedy dokázaly být v daném měsíci výhodnější, než jen pasivně sledovaná krátkodobá investice.

Z Tabulky 1 je také možnost vypočítat rozpor mezi úspěšností a výslednou bilancí prvních dvou modelů. Tento rozpor je dán zejména tím, že první model predikoval v jednom určitém dni opačný trend, který se na trhu vyskytl a zároveň v ten daný den byl zaznamenán pokles hodnoty o 1,89%, což druhý model dokázal predikovat a nepřipsal si ztrátu.

7.2. Optimalizace NAR modelu

Vzhledem k tomu, že neexistuje žádný ideální či univerzální NAR model, naskytá se využití optimalizace, a to nejenom díky velkému množství funkcí a jejich následných vlastností v systému Matlab, ale je stále vhodné brát v potaz, že u různých investičních položek se všechna nastavení či vlastnosti mohou projevit jak pozitivním tak i negativním výsledkem.

Optimalizace může probíhat v několika rovinách:

- Použitá data
- Vlastnosti a parametry modelu

Použitá data

Protože NAR model pracuje pouze s historickými daty zvoleného investičního nástroje, významně záleží jak na počtu tak také na trendu použitých dat. Konkrétně použité modely měly nastaveno, že z Yahoo! jsou stahována data za posledních 180 dní od uživatelem zvoleného data, což ve výsledku znamená, že jsou stažena data za cca. 125 obchodních dní.

Tento počet se jeví vhodný pro data, která mají relativně nízkou volatilitu – tedy nízkou míru kolísání hodnot. Pro data s velkou mírou kolísání hodnot existují dvě možnosti volby časového úseku pro predikci hodnot. První možností je snížit počet dat a zaměřit model jen na určitý interval vývoje daného investičního nástroje a druhou možností je naopak zvýšit počet historických dat, na kterých se bude model trénovat, kde může odhalit některé souvislosti vycházející z odvětvové fundamentální analýzy daného investičního nástroje a následně predikovat.

Data, která se dělí do podskupin, která jsou určena pro trénování, validaci a testování, můžeme taktéž ovlivnit způsobem rozřazení do těchto podskupin.

Pro rozdělení dat jsou určeny následující metody:

- dividerand – data jsou rozdělována do podskupin náhodným výběrem (tento způsob je také využíván),
- divideblock – data jsou rozdělována do souvislých bloků (data pro trénování tvoří první blok, pro validaci druhý a pro testování třetí blok),
- divideint – data jsou automaticky rozdělována do podskupin intervalově,
- divideind – data jsou rozdělena do podskupin dle manuálně nastavených intervalů.

Další možnost jak využít data pro možnou optimalizaci je v případě, kdy časový interval a počet neuronů se jeví jako dostačující, avšak výsledky jsou stále nepřesvědčivé. V takovémto případě je možnost změnit velikost trénovacího vektoru – čísla, které procentuálně vyjadřuje počet dat, na kterých je model natrénován anebo využití funkce (dividettrain), která se zapříčiní o to, že přiřadí všechna data pouze do podskupiny pro trénování a zbylé dvě zůstanou prázdné.

Vlastnosti a parametry modelu

Parametrické vlastnosti NAR modelu můžeme měnit v následujících rovinách:

- Obecná rovina, která se zabývá pojmenováním sítě nebo případného přidání vlastních informací o síti,
- Účinnost, která umožňuje nastavení např. vyrovnávací paměti pro přepočítávání zpožděných vstupů nebo paměti obecně,
- Architektury, jejíž vlastnosti určují počet vrstev a jejich typů a způsob jakými jsou propojeny,
- Funkcí – tyto vlastnosti definují jakým způsobem, se síť inicializuje, adaptuje, trénuje nebo se měří její výkonnost,

První (a také jedinou) možností, která byla během testování NAR modelů na konkrétním příkladě, byla změna počtu neuronů. Větší počet neuronů ve skryté vrstvě zvyšuje u modelu flexibilitu, jelikož neuronová síť má více parametrů, které je možné optimalizovat, ale zároveň je dobré mít na paměti, že počet využívaných neuronů je vhodné mít v určité korelaci s vstupním počtem dat, jelikož např. použití více neuronů než dat může docházet k výraznému zkreslování výsledku, protože neuronová síť musí přepočítávat více parametrů než je ve skutečnosti dat.

Krom čtyř základních přenosových (aktivačních) funkcí zmíněných v teoretické části, prostředí Matlab umožňuje využít dalších desítek funkcí, kde ovšem ne všechny jsou použitelné. Obdobná situace platí také u použití trénovacích algoritmů, kde je možnost využití jednoho z 21 algoritmů. Při případně nevyhovujícím Levenberg-Marquardt backpropagation algoritmu je vhodné využít algoritmu, využívajícího Bayesovu regularizaci (trainbr), který dokáže dobře generalizovat neuronovou síť. Regularizaci je taktéž možno nastavit manuálně za pomoci nastavení parametru výkonu sítě a nastavení vah, avšak při chybném nastavení může docházet k přeučení sítě a obecně je jednodušší využít výše zmíněné automatické regularizace.

Při zvolení trénovacího algoritmu, v mém případě Levenberg-Marquardt backpropagation (trainlm), který je považován za nejrychlejší backpropagation algoritmus, existuje další množství nastavení parametrů.

Některé možnosti z jeho nastavení jsou následující:

- net.trainParam.epochs – vyjadřuje maximální počet iterací (epoch),
- net.trainParam.goal – nastavení požadované výkonnosti sítě,
- net.trainParam.max_fail – maximální počet selhání při validaci atd.

Poslední možnou optimalizací, kterou zmíním, není optimalizace v pravém slova smyslu, ale jedná se způsob nahlížení na výpočet chyb.

Programové prostředí Matlab nabízí tyto možnosti:

- Mean absolute error (mae) – průměrná absolutní chyba - měří výkonnost sítě jako průměr z absolutních chyb,
- Mean squared error (mse) – průměrná střední kvadratická chyba – nejvyužívanější nástroj pro měření chyby,
- Sum squared error (sse) – způsob měření chyby při použití trainbr, kde je výkon vyjádřen v závislosti na součtu kvadrátů chyb

Shrnutí a zhodnocení NAR modelu

Predikční NAR model je velmi rychlý algoritmus, s jehož pomocí je možno dosáhnout téměř 75 procentní úspěšnosti odhadu vývoje trendu libovolného investičního nástroje. Při jeho jednoduchosti také existuje velké množství optimalizačních úprav kódu či metodik, za účelem zlepšování odhadu, které je však při hledání ideálního nastavení, díky velkému množství kombinací možností, velmi časově náročné.

Co se týče nevýhod tohoto modelu tak mezi největší patří fakt, že model pracuje pouze s určitou délkou historických dat, což u některých investičních nástrojů může být nedostačující, jelikož se na nich projevují např. sezónní nebo jiné vlivy popisované fundamentální analýzou. Použití modelu, při optimalizaci zaměřené na konkrétní investiční nástroj, je vhodné využívat jako podpůrný prostředek při rozhodování.

8. Nelineární autoregresní model s exogenními vstupy (NARX)

Pojem NARX, z anglického Nonlinear AutoRegressive (External) Exogenous input, je model, který jak už bylo zmíněno, využívá pro predikci kromě časové řady tvořené historickými hodnotami také další datové řady, které jsou přiváděny na exogenní vstupy modelu. Tyto vstupy následně ovlivňují výslednou predikci časové řady a měly by tedy s ní mít určitou spojitost.

Model matematicky může být popsán následujícím způsobem – máme-li časovou řadu $y(t)$ a další řadu $x(t)$, která je exogenním vstupem s celkovým počtem d hodnot výsledný matematický popis vypadá následovně:


$$y(t) = f(x(t-1) \dots x(t-d), y(t-1) \dots y(t-d)).$$

Jako exogenní parametry vstupující do modelu jsou využívány prostředky technické analýzy a jejich kombinace, které jsou prováděny na časové řadě.

Konkrétně se jedná o následující prostředky technické analýzy:


- Klouzavé průměry - jednoduché a exponenciální klouzavé průměry,
- MACD – ukazatel sbíhavosti a rozbíhavosti klouzavých průměrů,
- ROC – oscilátor popisující procentní změnu za zvolené období,
- RSI – index relativní síly,
- Stochastické oscilátory – oscilátory popisující hybnost v průběhu zvoleného časového období,
- WilliamsR – oscilátor popisující aktuální uzavírací hodnotu investičního nástroje v relaci s nejvyššími a nejnižšími cenami za zvolený počet dní,
- Bollingerova pásma – indikátor popisující volatilitu a relativní cenovou úroveň v určitém období investičního nástroje.

Základní schematické vyobrazení NARX modelu vychází z výše uvedeného matematického popisu a graficky je znázorněno na Obrázku 19.



Obrázek 19. Základní schéma modelu NARX
(Zdroj: vývojové prostředí Matlab)


V konkrétních případech, obdobně jako u NAR modelů, je grafické zobrazení modelu neuronové sítě ve svém popisu přesnější a detailnější. Zobrazení taktéž popisuje nastavení zpoždění, počet neuronů ve skryté vrstvě, transformační funkce vrstev ale také navíc číselně naznačuje, kolik exogenních vstupů je součástí neuronové sítě viz Obrázek 20.



Obrázek 20. Zobrazení konkrétního NARX modelu s 20 neurony
(Zdroj: vývojové prostředí Matlab)


Proces modelování neuronové sítě je velmi obdobný jako u NAR modelu. Data jsou rozdělena v poměru 0,7;0,15;0,15 (trénování, validace, test) s náhodným rozdělením do těchto podskupin. Zpoždění je nastaveno na 2 kroky, trénovací algoritmus je využíván Levenberg-Marquardt a chyba je měřena metodikou MSE. Program následně otevře okno zobrazující proces trénování a je vygenerován graf popisující, zda došlo k přetrénování sítě či nikoliv.

Následoval proces predikce a výsledná neuronová síť je zobrazena na Obrázku 21.




Obrázek 21. Predikční NARX model
(Zdroj: vývojové prostředí Matlab)

Následující obrázek (Obrázek č. 22) zobrazuje rozdíl mezi časovou řadou a predikovanými hodnotami společně se zobrazením odchylek v jednotlivých dnech. Rozdíl oproti NAR modelu spočívá v tom, že hodnoty nejsou predikovány od prvního bodu časové řady z důvodu, že nejsou ještě dostupné hodnoty vyplývající z technické analýzy prováděné na časové řadě.



Obrázek 22. Korelace časové řady a predikovaných hodnot NARX modelu
(Zdroj: vývojové prostředí Matlab)

Následující graf (Obrázek 23.) znázorňuje vývoj investičního nástroje společně s naznačením predikovaného vývoje na následující den. Graf vznikl překrytím historických hodnot časové řady s hodnotami predikovanými společně s naznačením budoucího vývoje trendu.



Obrázek 23. Zobrazení reálné a predikované hodnoty NARX modelu
(Zdroj: vývojové prostředí Matlab)

Nakonec, obdobně jako u NAR modelu z důvodu lepší přehlednosti a pro potřebu číselných podkladů, je generován slovní popis k predikci (Obrázek 24).

```
-----
Predikovaná hodnota k (datum, položka, cena):
    '31-Mar-2011'    'MSFT'    [25.1770]
```

```
Následující obchodní den je očekávan pokles ceny
-----
```

Obrázek 24. Slovní popis výstupu NARX modelu
(Zdroj: vývojové prostředí Matlab)

8.1. Vyhodnocení NARX modelu

Obdobně jako u NAR modelu neexistuje obecný predikční model, za pomoci něhož bych mohl nastavit základní parametry a vstupy sítě. Modelování probíhalo způsobem, že byla zvolena určitá kombinace vstupních veličin sítě a následně proběhla simulace na modelech sítí, které měly postupně 10, 20 a 50 neuronů a ostatní parametry zůstaly nezměněny. Jako vstupy modelů neuronové sítě byly využity všechny zmíněné indikátory zmíněné v kapitole „Technická analýza“, kdy jejich nastavení je dvojího provedení – s krokem 5 a 10 – což znamená, že všechny indikátory využívat ke svým výpočtům 5 případně 10 historických hodnot. U některých modelů byly také jako vstupní hodnoty brány některé z OHLC (Open, High, Low, Close) hodnot akcií.

Měření a vyhodnocení výsledků jednotlivých modelů probíhalo taktéž obdobně jako u NAR modelu, tedy byly založeny na odhadu hodnoty a trendu akcií společnosti Microsoft v měsíci březnu roku 2011. Výchozí obnos určený pro testování zvolen na hodnotě **\$100** a obchody probíhaly v závislosti na predikovaném trendu. V případě predikce růstu akcií byl uskutečněn nákup a v případě predikovaného poklesu byl uskutečněn prodej akcií.

Predikované výsledky byly zpětně konfrontovány s reálnými hodnotami, kde nejdůležitějšími milníky při vývoji kurzu akcií Microsoft za měsíc březen 2011 jsou následující možné výsledky na konci investičního (testovacího) období:

- Maximální možný zisk: **\$107,82**
- Maximální možná ztráta: **\$90,12**
- Akcie vedeny jako krátkodobá investice: **\$97,17**

První dva body je naznačují ideální případně nejhorší možný stav při nákupu a prodeji v daném měsíci. Poslední bod označuje stav, kdybychom se rozhodli vést tuto investici jako krátkodobou a celý měsíc s akciemi neobchodovali.

V následujících tabulkách se nachází vyhodnocení jednotlivých kombinací indikátorů technické analýzy a vstupních hodnot, kde je vždy naznačeno minimální a maximální odchylka odhadu hodnoty, úspěšnost odhadu trendu a výsledná bilance po měsíci obchodování s akciemi společnosti Microsoft. Tabulky jsou vždy ve dvojicích, kde vždy v první jsou výsledky se vstupy z technické analýzy s krokem 5 a v druhé s krokem 10.

V tabulkách č. 2 a 3 jsou uvedeny výsledky modelové řady neuronové sítě, kde jako vstupní hodnoty byly použity všechny indikátory technické analýzy a také OHLC ceny akcií. Z obou dvou tabulek je patrné, že od určité výše úspěšnosti odhadu je zajištěna profitabilita modelu.

Neúspěšnost modelů v prvním případě (Tabulka 2.) může být ovlivněna malým počtem neuronů sítě, kdy síť neměla dostatečný prostor pro trénování. V druhém případě (Tabulka 3.) se počet neuronů může jevit jako naopak příliš velký a síť již své výsledky generalizovala. V obou případech může být výsledek ovlivněn velkým množstvím oscilátorů na vstup neuronové sítě.

TA5; Indikátory: MA, EMA,MACD,RSI,Stoch. osc., Bollingerova pásma, Williams %R, OHLC			
Počet neuronů	Rozmezí odhadu hodnot [%]	Úspěšnost [%]	Výsledná bilance [\$]
10	0,107 - 4,978	56,52	98,75
20	0,079 - 4,648	73,91	101,81
50	0,137 - 7,098	73,91	102,8

Tabulka 2. NARX model se všemi indikátory TA (5)

TA10; Indikátory: MA, EMA,MACD,RSI,Stoch. osc., Bollingerova pásma, Williams %R,OHLC			
Počet neuronů	Rozmezí odhadu hodnot [%]	Úspěšnost [%]	Výsledná bilance [\$]
10	0,013 - 3,079	69,57	103,03
20	0,224 - 4,578	69,57	101,49
50	0,208 - 5,707	52,17	98,93

Tabulka 3. NARX model se všemi indikátory TA (10)

Následující dvě modelové řady (Tabulka 4. a Tabulka 5.) využívají k predikci následující hodnoty zejména oscilátory, což může být také kontraproduktivní, a dále všechny OHLC cenové hladiny bez použití, jakýchkoliv metod klouzavých průměrů, které by křivky vyhladily.

U prvního modelu v Tabulce 4., ačkoliv je úspěšnost odhadu trendu těsně nad 60 procent, je výsledná bilance pod hranicí \$100. Ačkoliv se odhad predikovaných hodnot od hodnot skutečných liší maximálně o cca 2,5% (jeden z nejnižších výsledků) model nedokázal odhadnout dva největší propady cen akcií v měsíci, což výslednou bilanci výrazně zhoršilo. Optimalizace modelu by mohla spočívat buďto v nahrazení některého

ze vstupů za některý z typů metody klouzavých průměrů nebo nenačítáním některých z OHL cenových hladin.

TA5; Indikátory:		ROC, RSI, Bollingerova pásma, Williams %R, OHLC	
Počet neuronů	Rozmezí odhadu hodnot [%]	Úspěšnost [%]	Výsledná bilance [\$]
10	0,269 - 2,431	60,87	98,36
20	0,308 - 4,93	60,87	100,79
50	0,206 - 4,68	73,91	103,6

Tabulka 4. NARX model s TA (5) vstupy - ROC, RSI, Bollingerova pásma, Williams %R, OHLC

U druhého modelu (Tabulka 5.) je úspěšnost velmi nízká, kde jako hlavní viníci se můžou jevit malý počet neuronů a velký počet oscilátorů případně parametrické nastavení těchto oscilátorů. Při podrobnější analýze tohoto modelu se predikované hodnoty jevily jako by byly posunuty o den napřed. Následující dva modely s větším počtem neuronů již byly profitabilní, i když rozmezí odhadu hodnot se v maximální hodnotě přiblížilo 10 procentům, avšak tato hodnota může být ovlivněna silným trendem.

TA10; Indikátory:		ROC, RSI, Bollingerova pásma, Williams %R, OHLC	
Počet neuronů	Rozmezí odhadu hodnot [%]	Úspěšnost [%]	Výsledná bilance [\$]
10	0,208 - 4,394	39,13	96,38
20	0,28 - 9,317	65,22	102,46
50	0,403 - 5,01	73,91	102,74

Tabulka 5. NARX model s TA (10) vstupy - ROC, RSI, Bollingerova pásma, Williams %R, OHLC

Následující dvě modelové řady (Tabulka 6. a Tabulka 7.) jako své vstupy využívají exponenciální klouzavé průměry, MACD, RSI index, Bollingerova pásma, stochastický oscilátor, Williams %R indikátor a Low a Close cenové hladiny akcie.

První modelová řada (Tabulka 6.) naznačuje, že při použití malého rozsahu u indikátorů technické analýzy a malého počtu neuronů je výsledná predikce docela úspěšná a také výnosná avšak při zvyšování počtu neuronů v síti klesá jak úspěšnost, tak i výnosnost. Případná optimalizace pro dosažení ještě vyšší úspěšnosti by mohla spočívat např. ve

změně typu metody klouzavého průměru nebo přidáním/odebráním některé z OHLC hodnot.

TA5; Indikátory: EMA, MACD, RSI, Bollingerova pásma, Stochastic. osc., Williams %R, LC			
Počet neuronů	Rozmezí odhadu hodnot [%]	Úspěšnost [%]	Výsledná bilance [\$]
10	0,019 - 5,344	69,56	105,16
20	0,086 - 10,137	60,87	103,13
50	0,129 - 8,016	56,52	100,27

Tabulka 6. NARX model s TA (5) vstupy - EMA, MACD, RSI, Bollingerova pásma, Stochasticický oscilátor, Williams %R, LC

U druhé modelové řady je situace naprosto opačná. Modely zaznamenaly výrazné ztráty a velmi nízkou úspěšnost odhadu trendu. Model patrně výrazně ovlivnila velikost kroků u jednotlivých indikátorů případně velikost Bollingerových pásem nebo stochastického oscilátoru. Nízké bilanční hodnoty jsou způsobeny zejména špatnými odhady trendů ve dnech, kdy byly zaznamenány největší poklesy cen akcií.

TA10; Indikátory: EMA, MACD, RSI, Bollingerova pásma, Stochastic. osc., Williams %R, LC			
Počet neuronů	Rozmezí odhadu hodnot [%]	Úspěšnost [%]	Výsledná bilance [\$]
10	0,286 - 4,741	52,17	96,47
20	0,005 - 10,097	60,87	102,71
50	0,053 - 11,329	56,52	98,2

Tabulka 7. NARX model s TA (10) vstupy - EMA, MACD, RSI, Bollingerova pásma, Stochasticický oscilátor, Williams %R, LC

Předposlední dvě testované modelové řady (Tabulka 8. a Tabulka 9.) využívají jako vstupní řady exponenciální klouzavé průměry, RSI index, stochastický oscilátor, Williams %R indikátor a Close hodnoty akcií.

U prvního modelu první modelové řady je zřetelná nízká úspěšnost odhadu trendu avšak rozmezí rozsahu odhadu hodnot je velmi úzké a výsledná bilance při takovéto nízké úspěšnosti je, sice minimálně, ale přeci, profitabilní. Zejména díky úzkému rozmezí odhadu hodnot se určitě vyplatí model dále optimalizovat – odebráním některého z oscilátorů, případně změna metody výpočtu klouzavých průměrů.

TA5; Indikátory:		EMA, ROC, RSI, Stoch. osc., Williams %R, Close	
Počet neuronů	Rozmezí odhadu hodnot [%]	Úspěšnost [%]	Výsledná bilance [\$]
10	0,134 - 2,81	43,47	100,54
20	0,046 - 5,328	65,22	102,59
50	0,023 - 5,681	56,52	100,49

Tabulka 8. NARX model s TA (5) vstupy - EMA, ROC, RSI, Stochastický oscilátor, Williams %R, Close hodnoty

Druhá modelová řada popisovaná v tabulce 9. se vyznačuje vysokou úspěšností a také vyšší výnosností u všech tří modelů. K dosažení vyšší výsledné bilance by mohlo být dosaženo optimalizačními kroky, kdy je možné změnit metodu výpočtu klouzavých průměrů, anebo změnou nastavení parametrů u oscilátorů.

TA10; Indikátory:		EMA, ROC, RSI, Stoch. osc., Williams %R, Close	
Počet neuronů	Rozmezí odhadu hodnot [%]	Úspěšnost [%]	Výsledná bilance [\$]
10	0,014 - 4,382	82,6	104,35
20	0,126 - 5,91	60,87	103,17
50	0,103 - 5,759	73,31	101,365

Tabulka 9. NARX model s TA (10) vstupy – EMA, ROC, RSI, Stochastický oscilátor, Williams %R, Close hodnoty

Poslední dvě modelové řady (Tabulka 10. a Tabulka 11.) přijímají na vstupu neuronové sítě hodnoty vycházející z metody klouzavých průměrů, ROC, RSI indexu a uzavírací hodnoty akcií.

Ačkoliv jsou modely mírně profitabilní tak zejména první model, který vykazuje vysokou úspěšnost je velmi málo profitabilní a je potřeba jej optimalizovat – pravděpodobně je nejjednodušším řešením úprava parametrů jednotlivých indikátorů.

TA5; Indikátory:		MA, ROC, RSI, Close	
Počet neuronů	Rozmezí odhadu hodnot [%]	Úspěšnost [%]	Výsledná bilance [\$]
10	0,086 - 5,005	73,92	100,54
20	0,277 - 8,279	65,22	102,15
50	0,144 - 8,297	52,17	100,25

Tabulka 10. NARX model s TA (5) vstupy – MA, ROC, RSI a Close

Poslední modelová řada (Tabulka 11.) je obdobně jako její předchůdce mírně profitabilní a v jednom případě dokonce i ztrátová, kde kroky k případné optimalizaci spočívají v parametrickém přenastavení indikátorů.

TA10; Indikátory:		MA, ROC, RSI, Close	
Počet neuronů	Rozmezí odhadu hodnot [%]	Úspěšnost [%]	Výsledná bilance [\$]
10	0,091 - 4,949	56,52	100,14
20	0,097 - 4,001	60,87	101,74
50	0,142 - 14,889	52,17	99,67

Tabulka 11. NARX model s TA (10) vstupy – MA, ROC, RSI, Close

8.2. Optimalizace NARX modelu

Stejně jako u NAR modelu procesy optimalizace mohou probíhat jak v rovině vstupních dat a jejich parametrických změn a tak také v parametrickém nastavování modelu v prostředí Matlab a to zejména z důvodu neexistence universálního řešení. Optimální výsledné řešení je však možné implementovat pouze na konkrétní investiční nástroj z důvodu jejich různorodosti.

Optimalizace vstupních dat a jejich parametrických změn

První možností optimalizace je zvětšení případně zmenšení počtu dnů historických dat, stahovaných z Yahoo! Finance, které vstupují do neuronové sítě a na kterých je taktéž prováděna technická analýza. Velikost intervalu při volbě počtu dat časové řady se odvíjí od volatility investičního nástroje. Pro velmi až extrémně volatilní investiční nástroje je vhodné využít buďto dlouhých časových řad z důvodu, aby neuronová síť měla dostatek dat pro natrénování sítě anebo tuto dlouhou časovou řadu rozdělit do kratších a zvolit intervalové řešení. Pro investiční nástroje s nízkou mírou kolísání hodnot není potřeba využívat dlouhých časových řad a za dostatečný počet dat můžeme považovat časový úsek v délce několika měsíců.

Jelikož tento model neuronové sítě obsahuje také exogenní vstup, na který může být přivedeno velké množství dat, které by měly mít nějakou souvztažnost s původní časovou řadou, existuje velké množství kombinací nejenom indikátorů vycházejících z technické analýzy. V mém konkrétním případě bylo využito 7 hlavních typů indikátorů, kde některé se svým charakterem dělí na další podskupiny a téměř všechny tyto indikátory se mohou parametricky měnit.

U jednotlivých indikátorů jsou to následující parametry:

- Klouzavé průměry – možnost volby mezi jednoduchým a exponenciálním typem klouzavého průměru, jediné parametrické nastavení je nastavení kroku či prodlevy, která udává počet předchozích datových bodů, které slouží k výpočtu průměru,
- ROC – u tohoto indikátoru je možné měnit počet předchozích datových bodů určených k výpočtu, kde jako výchozí nastavení je doporučována hodnota 12,
- RSI – jediný parametr tohoto indexu je nastavení periody použití datových bodů, kde výchozí doporučená hodnota periody je 14,

- Stochastické oscilátory – oscilátory je možné rozdělit na dva druhy a to na „Fast“ a „Slow“ oscilátor, které se liší v nastavení ve výpočtu, kdy první využívá „High“ a druhý „Low“ cenové hladiny. Parametricky je možno nastavit periody použití datových bodů a metodu výpočtu klouzavých průměrů (exponenciální nebo triangulární),
- WilliamsR – možnost parametrického nastavení tkví v nastavení periody používaných dat k výpočtu, kde výchozí doporučená hodnota je 14,
- Bollingerova pásma – pásma existují ve třech variantách, kde možnosti nastavení jsou ve volbě použití klouzavého průměru ke kalkulaci a počtu standardních odchylek pro horní a dolní pásmo – výchozí hodnota je rovna 2.

Financial Toolbox v prostředí Matlabu nabízí možnost výběru celkem z 24 jednoduše implementovatelných funkcí pro výpočet indikátorů technické analýzy, které dokážou počítat jak s cenami tak i objemy např. PVT (Price and Volume Trend), OBV (On-Balance Volume) a další. Spolu s možností využití vysokého počtu různých technických indikátorů a velkého množství jejich potenciálních kombinací, roste taktéž náročnost na optimalizaci u jednotlivých investičních nástrojů. Některé indikátory navíc mají podobný charakter (např. RSI, stochastický oscilátor a Williams %R), kde jejich různorodé výstupy mohou ve výsledku mít kontraproduktivní charakter – je tedy nutné je volit s určitou obezřetností a s podezřením na snížení přesnosti odhadu hodnoty nebo úspěšnosti odhadu trendu.

Z pohledu na doporučené hodnoty jednotlivých indikátorů lze vyčíst, že v mém případě periodičnost použití datových bodů pro výpočty byly v některých případech použity nižší hodnoty (5 a 10) a případná optimalizace se může naskýtat v jejich změně.

Při volbě specifického investičního nástroje je možno připojit na vstup neuronové sítě mimo jiné index **VIX** (^VIX). Tento index je měřítkem implicitní volatility pro index S&P500 – index popisuje očekávanou 30 denní volatilitu na trzích, které jsou právě tímto indexem reprezentovány. Tento zmiňovaný index má inverzní vztah k akciovým indexům. Pokud index S&P500 stoupá, index VIX klesá a obráceně. Tato vlastnost indexu dala označení „měřič strachu“. Pokud hodnoty indexu oscilují kolem hladiny 10 bodů, tak na trhu vládne spokojenost a u akcií se neočekávají žádné výraznější pohyby.

Pokud je index nad hladinou 30 bodů, která je již označována jako extrémně vysoká, popisuje stav, že nejistota na trzích je vysoká.²⁴

Použitá vstupní data můžeme dále optimalizovat způsoby, které nabízí prostředí Matlabu a jsou obdobné jako u NAR modelu.

Jedná se zejména o:

- Způsob rozdělení dat do podskupin, které jsou určeny pro trénování, validaci a testování neuronové sítě,
- Změna procentuální velikosti trénovacího, testovacího a validačního vektoru, případně využití všech dat pouze na trénování.

Parametrické nastavení modelu

Obdobně jako u NAR modelu můžeme NARX model optimalizovat ve dvou hlavních oblastech.

Tyto oblasti jsou následující:

- Oblast nastavování paměti – s velikostí délky časových řad také stoupá náročnost výpočtu a tak v některých případech je nutno nastavit využívání paměti,
- Oblast nastavení architektury sítě – nastavení vlastností určující počet neuronů, vrstev sítě, aktivačních funkcí nebo trénovacích funkcí nebo způsobů měření chyb.

Možností různých nastavení je velká řada a záleží na rozhodnutí uživatele, které parametry je dle něj vhodné přenastavit.

Shrnutí zhodnocení NARX modelu

Predikční NARX neuronová síť je rychlý algoritmus, s jehož pomocí je možno dosáhnout 82 procentní úspěšnosti odhadu trendu určitého investičního nástroje. Takto vysoké úspěšnosti lze dosáhnout jen velmi těžce a ve velmi omezeném počtu případů.

S úspěšností odhadu trendu je spojená také profitabilita, kde maximální zhodnocení za měsíc obchodování, kterého bylo dosaženo je na úrovni 5.16% (\$105,16) což dosahuje úrovně na hladině 97 procent z celkového maximálního zhodnocení investičního nástroje. Dalším zajímavým faktem je, že pokud je dosaženo úspěšnosti odhadu trendu

²⁴ VIX: měřič strachu, který napoví kdy investovat [25]

nad 60 procent tak v 18 z 19 případů je model profitabilní, což značí, že není nutností mít model s velmi vysokou úspěšností odhadu.

Z výše uvedených tabulek je také možné vyzorovat, že se občas predikovaná hodnota značně liší od skutečné někdy i o cca 10 procent, což však nepopisuje chybovost modelu, ale pouze neuronová síť narazila na silně růstový/poklesový trend.

Výhodou tohoto modelu je jednoduché nastavení vstupů a parametrů neuronové sítě.

Nevýhodou je neexistence univerzálního řešení a díky velkému množství možností nastavení parametrů indikátorů vycházejících z technické analýzy a také díky velkému množství kombinací samotných indikátorů, které jsou přiváděny na exogenní vstup neuronové sítě, je nalezení optimálního modelu velmi náročné.

Při výsledném použití optimalizovaného NARX modelu na konkrétní investiční nástroj ve spojení s prováděním jednoduchých fundamentálních analýz, je možné pohodlně a profitabilně investovat.

9. Závěr

Diplomová práce je zaměřena využití umělých neuronových sítí za účelem predikce na kapitálových trzích. V praktické části této práce jsou popsány a vytvořeny dva modelové typy (NAR a NARX), které byly testovány a následně vyhodnocena jejich úspěšnost.

U prvního modelu (NAR), který pro predikci využíval pouze historické hodnoty uživatelem zvoleného investičního nástroje, bylo dosaženo 73,9 procentní úspěšnosti odhadu trendu vývoje na následující obchodní den, což ve výsledku znamenalo 3,16 procentní zhodnocení investovaného kapitálu.

Druhý model (NARX) využíval kromě historických hodnot také data vycházející z technické analýzy. U tohoto modelu bylo dosaženo 82,6 procentní úspěšnosti odhadu trendu, což znamenalo 4,35 procentní zhodnocení investovaného kapitálu.

Nevýhodami obou dvou modelů je nutnost optimalizace na různých úrovních (datová, parametrická, případně kombinace vstupních indikátorů technické analýzy) a předpoklad, že uživatel vlastní licenci k vývojovému prostředí Matlab, i když existuje možnost kompilace zdrojových kódů a za pomoci „spouštěčů“ používat zdarma a bez nutnosti instalace prostředí Matlab.

Oba dva typy modelů vykazují velmi dobré výsledky v úspěšnosti odhadu trendu. První model je možno, díky závislosti pouze na časové řadě tvořenou pouze historickými daty, využívat jako podpůrný prostředek při rozhodování. Druhý model, díky vstupním hodnotám vycházející z technické analýzy, lze velmi dobře využívat ke krátkodobému obchodování na kapitálových trzích.

10. Seznam použité literatury a zdrojů

Odborná literatura

1. ARBIB, Michael. *The handbook of brain theory and neural networks*. 2. vyd. The MIT Press, 2002. 1344 s. ISBN 02-620-1197-2
2. DOSTÁL, Petr. *Pokročilé metody analýz a modelování v podnikatelství a veřejné správě*. Vyd. 1. Brno: CERM, 2008. 340 s. ISBN 978-807-2046-058.
3. FANTA, Jiří. *Psychologie, algoritmy a umělá inteligence na kapitálových trzích*. 1. vyd. Praha: Grada, 2001. 167 s. ISBN 80-247-0024-7.
4. KROPÁČ, Jiří. *Statistika B: jednorozměrné a dvourozměrné datové soubory, regresní analýza, časové řady*. 1. vyd. Brno, 2007. 149 s. ISBN 80-214-3295-0.
5. MARČEK, Milan; PANČÍKOVÁ, Lucia; MARČEK, Dušan. *Ekonometria a soft computing*. Žilina, 2008. 271 s. ISBN 978-808-0707-460.
6. PAVLÁT, Vladislav. *Kapitálové trhy*. 2. dopl. vyd. Praha: Professional Publishing, c2005. 318 s. ISBN 80-864-1987-8.

Elektronické zdroje

7. Bollingerova pásma [online]. [cit. 2011-05-09]. Dostupné z WWW: <http://cs.wikipedia.org/wiki/Bollingerova_p%C3%A1sma>
8. ČEKIA - Počet firem vzrostl za posledních pět let o čtvrtinu (ceskapozice.cz) [online]. [cit. 2011-03-31]. Dostupné z WWW: <<http://www.cekia.cz/cz/napsali-onas/212-nn110125ceskapozicecz>>
9. ČSÚ - Nejnovější ekonomické údaje [online]. [cit. 2011-03-31]. Dostupné z WWW: <<http://www.czso.cz/csu/csu.nsf/aktualniinformace>>
10. ČSÚ - Obyvatelstvo [online]. [cit. 2011-03-31]. Dostupné z WWW: <[http://www.czso.cz/csu/2010edicniplan.nsf/t/ED00377ECC/\\$File/14091005.pdf](http://www.czso.cz/csu/2010edicniplan.nsf/t/ED00377ECC/$File/14091005.pdf)>
11. Index relativní síly [online]. [cit. 2011-05-09]. Dostupné z WWW: <http://cs.wikipedia.org/wiki/Relative_Strenght_Index>
12. Indikátory technické analýzy [online]. [cit. 2011-05-09]. Dostupné z WWW: <<http://www.akcieatrhy.cz/cz/technicka-analyza-hlavni-strana>>
13. Kapitálový trh [online]. [cit. 2011-02-12]. Dostupné z WWW: <http://cs.wikipedia.org/wiki/Kapit%C3%A1lov%C3%BD_trh>

14. MACD: Téměř "svatý grál" [online]. [cit. 2011-05-09]. Dostupné z WWW: <<http://www.investujeme.cz/clanky/macd-temer-svaty-gral/>>
15. MathWorks - Neural Network Toolbox [online]. [cit. 2011-03-31]. Dostupné z WWW: <<http://www.mathworks.com/help/toolbox/nnet/>>
16. Matlab - Jazyk pro technické výpočty [online]. [cit. 2011-05-09]. Dostupné z WWW: <<http://www.humusoft.cz/produkty/matlab/matlab/>>
17. MIXA Vending - Profil společnosti [online]. [cit. 2011-03-10]. Dostupné z WWW: <<http://www.mixa.cz/profil-spolecnosti/>>
18. Momentum (technical analysis) [online]. [cit. 2011-05-09]. Dostupné z WWW: <[http://en.wikipedia.org/wiki/Rate_of_change_\(technical_analysis\)](http://en.wikipedia.org/wiki/Rate_of_change_(technical_analysis))>
19. Neuron [online]. [cit. 2011-03-31]. Dostupné z WWW: <<http://cs.wikipedia.org/wiki/Neuron>>
20. Počátky burzovníctví [online]. [cit. 2011-02-12]. Dostupné z WWW: <<http://www.finance.cz/kapitalovy-trh/informace/burza-praha/historie-burzovnictvi/>>
21. Predikce [online]. [cit. 2011-02-12]. Dostupné z WWW: <<http://cs.wikipedia.org/wiki/Predikce>>
22. Spotřební daň z tabáku se opět zvedne, krabička cigaret zdraží o 2 koruny [online]. [cit. 2011-03-31]. Dostupné z WWW: <http://byznys.lidovky.cz/spotrebni-dan-z-tabaku-se-opet-zvedne-krabicka-cigaret-zdrazi-o-2-koruny-13z-/moje-penize.asp?c=A100618_120455_moje-penize_nev>
23. Transparency International - Vývoj hodnot indexu CPI v České republice v letech 1997 až 2010 [online]. [cit. 2011-03-31]. Dostupné z WWW: <http://www.transparency.cz/doc/publikace/indexy/cpi_2010/CPI2010_Vyvoj_indexu_CPI_1997_2010.pdf>
24. Umělé neuronové sítě pomáhají lékařům FN Motol [online]. [cit. 2011-03-31]. Dostupné z WWW: <<http://www.3pod.cz/254-Umele-neuronove-site-pomahaji-lekarum-FN-Motol.html>>
25. VIX: měřič strachu, který napoví kdy investovat [online]. [cit. 2011-05-10]. Dostupné z WWW: <<http://www.investujeme.cz/clanky/vix-meric-strachu-ktery-napovi-kdy-investovat/>>

26. Seznam obrázků

Obrázek 1. SWOT analýza společnosti, zdroj: vlastní	14
Obrázek 2. Biologický neuron.....	23
Obrázek 3. Graficky zobrazený matematický neuron.....	24
Obrázek 4. Topologie neuronové sítě 4-5-1	26
Obrázek 5. Skoková aktivační funkce	28
Obrázek 6. Lineární aktivační funkce	28
Obrázek 7. Logistická aktivační funkce	29
Obrázek 8. Hyperbolická tangenta (aktivační funkce)	29
Obrázek 9. Obecné schéma práce neuronové sítě	32
Obrázek 10. Základní schéma modelu NAR	42
Obrázek 11. Zobrazení konkrétního NAR modelu s 20 neurony	42
Obrázek 12. Trénování neuronové sítě u NAR modelu	43
Obrázek 13. MSE graf	44
Obrázek 14. Predikční NAR model	44
Obrázek 15. Korelace časové řady a predikovaných hodnot.....	45
Obrázek 16. Zobrazení reálné a predikované hodnoty NAR modelu	45
Obrázek 17. Přiblížení predikce růstového trendu NAR modelu.....	46
Obrázek 18. Slovní popis výstupu NAR modelu	46
Obrázek 19. Základní schéma modelu NARX	53
Obrázek 20. Zobrazení konkrétního NARX modelu s 20 neurony	53
Obrázek 21. Predikční NARX model	54
Obrázek 22. Korelace časové řady a predikovaných hodnot NARX modelu	54
Obrázek 23. Zobrazení reálné a predikované hodnoty NARX modelu	55
Obrázek 24. Slovní popis výstupu NARX modelu	55

27. Seznam tabulek

Tabulka 1. Zhodnocení NAR modelů	47
Tabulka 2. NARX model se všemi indikátory TA (5)	57
Tabulka 3. NARX model se všemi indikátory TA (10)	57
Tabulka 4. NARX model s TA (5) vstupy - ROC, RSI, Bollingerova pásma, Williams %R, OHLC	58
Tabulka 5. NARX model s TA (10) vstupy - ROC, RSI, Bollingerova pásma, Williams %R, OHLC	58
Tabulka 6. NARX model s TA (5) vstupy - EMA, MACD, RSI, Bollingerova pásma, Stochasticický oscilátor, Williams %R, LC	59
Tabulka 7. NARX model s TA (10) vstupy - EMA, MACD, RSI, Bollingerova pásma, Stochasticický oscilátor, Williams %R, LC	59
Tabulka 8. NARX model s TA (5) vstupy - EMA, ROC, RSI, Stochasticický oscilátor, Williams %R, Close hodnoty	60
Tabulka 9. NARX model s TA (10) vstupy – EMA, ROC, RSI, Stochasticický oscilátor, Williams %R, Close hodnoty	60
Tabulka 10. NARX model s TA (5) vstupy – MA, ROC, RSI a Close	61
Tabulka 11. NARX model s TA (10) vstupy – MA, ROC, RSI, Close	61

28. Seznam příloh

Příloha 1.: soubor NAR.m

Příloha 2.: soubor NARX.m

Příloha 1 – Zdrojový kód nelineárního autoregresního modelu (NAR)

```
%% Clearing screen and suppressing warnings
clc;
clear all;

warning('off', 'MATLAB:mat2cell:ObsoleteSingleInput');
warning('off', 'MATLAB:datetime:EmptyDate');
%% Input screen
display('Predikce vybraného ukazatele');
display(' ');
disp('Jednotlivé zkratky je možné najít na <a href =  
"http://finance.yahoo.com/">Yahoo Finance</a>.; ');
display('Příklady zkratk: MSFT - Microsoft Corp., GOOG -  
Google Inc. atd.');
```

```
display(' ');
vyber_položky = input('Zadej zkratku ukazatele, se kterým se  
bude pracovat: ', 's'); % parametr 's' označuje, že vrací  
string
if isempty(vyber_položky)
    display('Nebyl vybrán žádný ukazatel - jako defaultní je  
zvolen MSFT');
    vyber_položky = 'MSFT';
end
datum = datetime(input('Pro který den se bude predikovat hodnota?  
(MM-DD-YYYY):', 's')); %datum ve formátu serial date number
if isempty(datum)
    display(' ');
    display('Nebylo vybráno žádné datum - jako defaultní je  
zvoleno dnešní datum');
    datum = datetime(today);
end

%% Connecting to Yahoo
Connect = yahoo;

toDate = datum; % jen at se mi to neplete
fromDate = toDate - 180; % jde 180dnů dozadu od zadaného data
nacteni_hodnot = fetch(Connect, vyber_položky, {'Close'},  
fromDate, toDate); % bude brát cenu při uzavření, další  
možnosti, High, Low, Open,

data = flipud(nacteni_hodnot); % překlopení dat

%% Target data
```

```

pocet_hodnot = length(data(:,2));
osekana_tsdata= data(:,2);
pripravena_data = reshape(osekana_tsdata,1,pocet_hodnot);

targetSeries = tonndata(pripravena_data,true,false);

%% Nonlinear Autoregressive Network
feedbackDelays = 1:2;
hiddenLayerSize = 20;
net = narnet(feedbackDelays,hiddenLayerSize);

% Feedback Pre/Post-Processing Functions
% list of all processing functions - nnprocess
net.inputs{1}.processFcns = {'removeconstantrows','mapminmax'};

% Prepare the Data for Training and Simulation
[inputs,inputStates,layerStates,targets] =
preparets(net,{}, {},targetSeries);

% Setup Division of Data for Training, Validation, Testing
net.divideFcn = 'dividerand';
net.divideParam.trainRatio = 70/100;
net.divideParam.valRatio = 15/100;
net.divideParam.testRatio = 15/100;

% Training Function
% list of all training functions - nntrain
net.trainFcn = 'trainlm'; % Levenberg-Marquardt

% Choose a Performance Function
% list of all performance functions - nnperformance
net.performFcn = 'mse'; % Mean squared error

% Choose Plot Functions
% list of all plot functions - nnplot
net.plotFcns = {'plotperform','plottrainstate','plotresponse',
'ploterrcorr', 'plotinerrcorr'};

% Train the Network
[net,tr] = train(net,inputs,targets,inputStates,layerStates);

% Test the Network
outputs = net(inputs,inputStates,layerStates);
errors = gsubtract(targets,outputs);
performance = perform(net,targets,outputs);

% Recalculate Training, Validation and Test Performance
trainTargets = gmultiply(targets,tr.trainMask);
valTargets = gmultiply(targets,tr.valMask);
testTargets = gmultiply(targets,tr.testMask);
trainPerformance = perform(net,trainTargets,outputs);
valPerformance = perform(net,valTargets,outputs);
testPerformance = perform(net,testTargets,outputs);

```



```

%% Diagrams and plots

% View the Network diagram
view(net);

% Early Prediction Network
nets = removedelay(net);
nets.name = [net.name ' One step prediction network'];
view(nets)

[xs,xis,ais,ts] = preparets(nets,{}, {},targetSeries);
ys = nets(xs,xis,ais);

ff = pocet_hodnot-1;

% Plot
figure, plotperform(tr);
figure, plotresponse(targets,outputs);

figure('name','NAR');
hold on;
plot(cell2mat(ys(1:1,1:ff)),'-r+')
plot(cell2mat(targetSeries(1:1,3:pocet_hodnot)),'.-g')
hold off;
legend('Predikovaná hodnota','Casová rada');
ylabel('Cena')
xlabel('Pocet dni')
title('NAR');

%% Output screen

display(' ');
display('-----');
display('-----');
predicted_price = cell2mat(ys(ff));
historic_price = pripravena_data(pocet_hodnot);

if (historic_price < predicted_price)
    text_desc = 'Nasledující obchodní den je očekávan rust ceny';
else
    text_desc = 'Nasledující obchodní den je očekávan pokles
ceny';
end

display('Predikovaná hodnota k (datum, položka, cena): ');
display([datestr(datum+1), vyber_položky,
mat2cell(predicted_price)]);
disp(text_desc);
display('-----');
display('-----');

```

Příloha 2 – Zdrojový kód nelineárního autoregresního modelu s exogeními vstupy (NARX)

```
%% Clearing screen and suppressing warnings
clc;
clear all;

warning('off', 'MATLAB:mat2cell:ObsoleteSingleInput');
warning('off', 'MATLAB:datetime:EmptyDate');
%% Input screen
display('Predikce vybraného ukazatele');
display(' ');
disp('Jednotlivé zkratky je možné najít na <a href =  
"http://finance.yahoo.com/">Yahoo Finance</a>.; ');
display('Příklady zkratk: MSFT - Microsoft Corp., GOOG -  
Google Inc. atd.');
```

```
display(' ');
vyber_polozky = input('Zadej zkratku ukazatele, se kterým se  
bude pracovat: ', 's'); % parametr 's' označuje, že vrací  
string
if isempty(vyber_polozky)
    display('Nebyl vybrán žádný ukazatel - jako defaultní je  
zvolen MSFT');
    vyber_polozky = 'MSFT';
end
datum = datetime(input('Pro který den se bude predikovat hodnota?  
(MM-DD-YYYY):', 's')); % datum ve formátu serial date number
if isempty(datum)
    display(' ');
    display('Nebylo vybráno žádné datum - jako defaultní je  
zvoleno dnešní datum');
    datum = datetime(today);
end

%% Connecting to Yahoo
Connect = yahoo;

toDate = datum; % jen at se mi to neplete
fromDate = toDate - 180; % jde 180dnů dozadu od zadaného data
nacteni_hodnot = fetch(Connect, vyber_polozky, {'OPEN' 'HIGH'  
'LOW' 'CLOSE'}, fromDate, toDate);

data = flipud(nacteni_hodnot); % překlopení dat

%% Target data
pripravena_data = data';

osekana_data = pripravena_data(5,1:end);

%% Technical analysis
```

```

MA5 = tsmovavg(osekana_data, 's', 5);
MA10 = tsmovavg(osekana_data, 's', 10);
ExMA5 = tsmovavg(osekana_data, 'e', 5);
ExMA10 = tsmovavg(osekana_data, 'e', 10);
MACD = macd(osekana_data);
ROC5 = prcroc(osekana_data, 5);
ROC10 = prcroc(osekana_data, 10);
RSI5 = rsindex(data(1:end, 5), 5);
RSI10 = rsindex(data(1:end, 5), 10);
WilliamsR5 =
willpctr(data(1:end, 3), data(1:end, 4), data(1:end, 5), 5);
WilliamsR10 =
willpctr(data(1:end, 3), data(1:end, 4), data(1:end, 5), 10);

%Stochastic oscillators
ST_osc =
stochosc(data(1:end, 3), data(1:end, 4), data(1:end, 5), 10, 5, 'e');
FastStoch = ST_osc(1:end, 1)';
SlowStoch = ST_osc(1:end, 2)';

%Bollinger band
[mid5 upper5 lower5] = bollinger(data(1:end, 5), 5, 1);
Blower5 = lower5';
Bmid5 = mid5';
Bupper5 = upper5';

[mid10 upper10 lower10] = bollinger(data(1:end, 5), 10, 1);
Blower10 = lower10';
Bmid10 = mid10';
Bupper10 = upper10';

%% Input matrix

input = pripravena_data([2:4], :);
input(end+1, :) = MA5;
input(end+1, :) = ExMA5;
input(end+1, :) = MACD;
input(end+1, :) = ROC5;
input(end+1, :) = RSI5;
input(end+1, :) = WilliamsR5;
input(end+1, :) = SlowStoch;
input(end+1, :) = Blower5;
input(end+1, :) = Bmid5;
input(end+1, :) = Bupper5;

inputSeries = tonndata(input, true, false);
targetSeries = tonndata(osekana_data, true, false);

%%
% Create a Nonlinear Autoregressive Network with External Input
inputDelays = 1:2;
feedbackDelays = 1:2;

```

```

hiddenLayerSize = 20;
net = narxnet(inputDelays,feedbackDelays,hiddenLayerSize);

net.inputs{1}.processFcns = {'removeconstantrows','mapminmax'};
net.inputs{2}.processFcns = {'removeconstantrows','mapminmax'};

% Prepare the Data for Training and Simulation

[inputs,inputStates,layerStates,targets] =
preparets(net,inputSeries,{},targetSeries);

net.divideParam.trainRatio = 70/100;
net.divideParam.valRatio = 15/100;
net.divideParam.testRatio = 15/100;

% Choose a Training Function
% For a list of all training functions type: help nntrain

net.trainFcn = 'trainlm'; % Levenberg-Marquardt

% Choose a Performance Function
% For a list of all performance functions type: help
nnperformance

net.performFcn = 'mse'; % Mean squared error

% Choose Plot Functions
% For a list of all plot functions type: help nnplot

net.plotFcns = {'plotperform','plottrainstate','plotresponse',
...
'ploterrcorr','plotinerrcorr'};

% Train the Network
[net,tr] = train(net,inputs,targets,inputStates,layerStates);

% Test the Network
outputs = net(inputs,inputStates,layerStates);
errors = gsubtract(targets,outputs);
performance = perform(net,targets,outputs);

% Recalculate Training, Validation and Test Performance
trainTargets = gmultiply(targets,tr.trainMask);
valTargets = gmultiply(targets,tr.valMask);
testTargets = gmultiply(targets,tr.testMask);
trainPerformance = perform(net,trainTargets,outputs);
valPerformance = perform(net,valTargets,outputs);
testPerformance = perform(net,testTargets,outputs);

% View the Network
view(net);

```

```

% Early Prediction Network
nets = removedelay(net);
nets.name = [net.name ' - Predict One Step Ahead'];
view(nets)
[xs,xis,ais,ts] = preparets(nets,inputSeries,{},targetSeries);
ys = nets(xs,xis,ais);
earlyPredictPerformance = perform(nets,ts,ys);

pocet_hodnot = length(data(:,1));
ff = pocet_hodnot-1;
ys(ff);

% Plots
figure, plotperform(tr);
figure, plotresponse(targets,outputs)

figure('name','NARX');
hold on;
plot(cell2mat(ys(1:1,1:ff)),'-r+')
plot(cell2mat(targetSeries(1:1,3:pocet_hodnot)),'.-g')
hold off;
legend('Predikovaná hodnota','Casová rada');
ylabel('Cena')
xlabel('Pocet dni')
title('NARX');

%% Output screen
display(' ');
display('-----');
display('-----');
predicted_price = cell2mat(ys(ff));
historic_price = pripravena_data(pocet_hodnot);

if (historic_price < predicted_price)
    text_desc = 'Nasledujici obchodni den je ocekavan rust ceny';
else
    text_desc = 'Nasledujici obchodni den je ocekavan pokles
ceny';
end

display('Predikovaná hodnota k (datum, položka, cena): ');
display([datestr(datum+1), vyber_položky,
mat2cell(predicted_price)]);
disp(text_desc);
display('-----');
display('-----');

```